



**T.C. SAđLIK BİLİMLERİ NİVERSİTESİ, GLHANE TIP  
FAKLTESİ RADYOLOĐİ ANA BİLİM DALI VE  
GLHANE SAđLIK UYGULAMA VE ARAřTIRMA MERKEZİ  
RADYOLOĐİ KLİNİĐİ**

**RADYOLOĐİK GRNTLEMEDE YAPI ZMLEME  
UYGULAMALARI**

**Dr. Mehmet ERŐEN**

**TIPTA UZMANLIK TEZİ**

**ANKARA/2019**



**T.C. SAĞLIK BİLİMLERİ ÜNİVERSİTESİ, GÜLHANE TIP  
FAKÜLTESİ RADYOLOJİ ANA BİLİM DALI VE  
GÜLHANE SAĞLIK UYGULAMA VE ARAŞTIRMA MERKEZİ  
RADYOLOJİ KLİNİĞİ**

**RADYOLOJİK GÖRÜNTÜLEMEDE YAPI ÇÖZÜMLEME  
UYGULAMALARI**

**Dr. Mehmet ERŞEN**

**Tez Danışmanı: Prof. Dr. Hatice Tuba SANAL**

**TIPTA UZMANLIK TEZİ**

**ANKARA/2018**

Sağlık Bilimleri Üniversitesi Gülhane Eğitim ve Araştırma Hastanesi Dekanlığına:

**“RADYOLOJİK GÖRÜNTÜLEMEDE YAPI ÇÖZÜMLEME UYGULAMALARI”** konulu bu çalışmamız jürimiz tarafından Radyoloji Anabilim Dalı’nda Uzmanlık Tezi olarak kabul edilmiştir.

İMZA:

Tez Danışmanı	: Prof. Dr. Hatice Tuba SANAL	.....
Başkan	: Prof. Dr. Mustafa TAŞAR	.....
Üye	: Prof. Dr. Hatice Tuba SANAL	.....
Üye	: Prof. Dr. Tuncay HAZIROLAN	.....
Yd. Üye	: Prof. Dr. Deniz AKATA	.....
Yd. Üye	: Prof. Dr. Uğur BOZLAR	.....

Dr. Mehmet ERŞEN’in 17.06.2019 tarihinde savunduğu bu tez Akademi Kurulu’nca belirlenen yukarıdaki jüri üyeleri tarafından uygun görülmüş ve kabul edilmiştir.

DEKAN

Prof. Dr. Muzaffer KIRIŞ  
Sağlık Bilimleri Üniversitesi  
Gülhane Tıp Fakültesi Dekanı

## TEŞEKKÜR

Bu tez çalışması, 38 numaralı etik kurul karar ve 46418926 numaralı üst yazısı gereği SBÜ Gülhane Eğitim ve Araştırma Hastanesi Radyoloji Kliniğinde yapılmıştır.

Bu çalışmada, radyolojik görüntülemelerde yapı çözümü uygulamalarından tekstür analizini kullanarak renal hücreli kanserin alt gruplarının ve onkositomun MR bulguları ile patolojik verileri arasında doku yapısal özellikleri açısından korelasyon ve diğer ilişkilerin araştırılması hedeflenmiştir.

Uzmanlık eğitimim süresince bilgi ve tecrübeleri ile yolumu aydınlatan değerli hocam, Sayın Prof. Dr. Mustafa TAŞAR'a derin saygı ve teşekkürlerimi sunarım.

Asistan olarak geçirdiğim her anından büyük mutluluk ve gurur duyduğum Gülhane Eğitim ve Araştırma Hastanesi Radyoloji Kliniğinde, her alanda desteklerini benden esirgemeyen değerli öğretim üyelerim Prof. Dr. H. Tuba SANAL'a, Prof. Dr. Uğur BOZLAR'a, Prof. Dr. Kemal N. ARDA'ya, Dr.Öğr.Üyesi Sinan AKAY'a ve Dr.Öğr.Üyesi Ferhat CÜCE'ye şükran ve saygılarımı sunarım.

Çalışmanın istatistik kısmında büyük emeği geçen İstanbul Medeniyet Üniversitesinde görevine devam eden değerli dostum Sn. Abdülkadir KESKİN'e teşekkür ederim.

Uzmanlık eğitimim süresince birlikte çalıştığım meslektaşlarım olan değerli asistan arkadaşlarıma, anjiyografi ünitesinde birlikte çalıştığım değerli teknisyen arkadaşlarıma ve hemşire hanımlara ve tüm Gülhane Eğitim ve Araştırma Hastanesi Radyoloji Kliniği personeline teşekkürlerimi sunarım.

Hayatım boyunca yanımda olan ve benim için her türlü fedakarlığa katlanan sevgili aileme,

Sabri ve fedakarlığıyla daima yanımda olan hayat arkadaşım Rabia'ya en içten sevgilerimi ve sonsuz teşekkürlerimi sunarım.

## KISALTMALAR

2B	: İki boyutlu
3B	: Üç boyutlu
AML	: Anjiyomyolipom
AUC	: Eğri altındaki alan (Area Under the Curve)
BT	: Bilgisayarlı Tomografi
COM	: Eşdizilim matrisi (Co-occurrence Matrix, Grey Level Co-occurrence)
DICOM	: Digital Imaging and Communications in Medicine
HU	: Hounsfield Birimi
k-NN	: k-En Yakın Komşu (K-Nearest Neighborhood)
LDA	: Lineer diskriminant analizi (Linear discriminant analysis)
MR	: Manyetik Rezonans
MRG	: Manyetik Rezonans Görüntüleme
NEX	: Faz tekrarlama sayısı (Number of excitation)
NSA	: Faz tekrarlama sayısı (Number of signal averaged)
PCA	: Temel bileşen analizi (Principal component analysis)
PET	: Pozitron Emisyon Tomografisi
POE	: Sınıflama hatası olasılığı (Probability of classification error)
RHK	: Renal Hücreli Kanser
RLM	: Tekrar Uzunluğu Matrisi (Run Length Matrix)
ROI	: İlgi Bölgesi (Region of interest)
TA	: Yapısal Analiz (Texture Analysis)
TE	: Eko zamanı (time to echo)
TR	: Tekrarlama zamanı (Time to repeat)
US	: Ultrasonografi
VHL	: Von Hippel-Lindau
WHO	: Dünya Sağlık Örgütü (World Health Organization)

# İÇİNDEKİLER

<b>TEŞEKKÜR</b> .....	<b>iii</b>
<b>KISALTMALAR</b> .....	<b>iv</b>
<b>İÇİNDEKİLER</b> .....	<b>v</b>
<b>TABLO LİSTESİ</b> .....	<b>vii</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>ix</b>
<b>ÖZET</b> .....	<b>x</b>
<b>ABSTRACT</b> .....	<b>xi</b>
<b>1. GİRİŞ VE AMAÇ</b> .....	<b>1</b>
<b>2. GENEL BİLGİLER</b> .....	<b>3</b>
2.1. DOKU YAPISAL ANALİZİ .....	3
2.1.1. Tekstür Analizi Süreci.....	4
2.1.1.1. Görüntü kazanımı .....	4
2.1.1.2. İlgi bölgesi (Region of interest- ROI) seçimi:.....	5
2.1.1.3. ROI ön işleme.....	7
2.1.1.4. Özellik çıkarımı .....	9
2.1.1.4.1. İstatistiksel yöntemler.....	9
2.1.1.4.2. Model-temelli yöntemler .....	12
2.1.1.4.3. Dönüşüm-temelli yöntemler .....	12
2.1.1.5. Özellik seçimi ve azaltımı.....	13
2.1.1.6. Sınıflama .....	15
2.1.2. Tekstür Analiz Yazılımları .....	15
2.2. RENAL KİTLELER.....	16
2.2.1. Malign Renal Lezyonlar .....	18
2.2.1.1. Renal Hücreli Kanser (RHK) .....	18
2.2.1.2. Renal lenfoma.....	21
2.2.1.3. Metastaz .....	21
2.2.2. Benign Renal Lezyonlar .....	21
2.2.2.1. Anjiomiyolipom (AML) .....	21
2.2.2.2. Onkositom .....	22
2.2.2.3. İnflamatuvar Durumlar ve Psödotümörler .....	23
<b>3. GEREÇ VE YÖNTEM</b> .....	<b>24</b>

3.1. OLGULAR.....	24
3.2. GÖRÜNTÜLEME.....	24
3.3. TEKSTÜR ANALİZİ.....	25
3.3.1. ROİ (region of interest) Çizimi.....	25
3.3.2. ROİ Ön Hazırlığı.....	26
3.3.3. Tekstür Özelliklerinin çıkarımı.....	26
3.3.4. Tekstür Özelliklerinin seçimi .....	26
3.5. İSTATİSTİKSEL ANALİZ .....	26
<b>4. BULGULAR.....</b>	<b>28</b>
4.1. RHK – ONKOSİTOM VE RHK ALT TİPLERİNİN AYRIMINA YÖNELİK ANALİZLER .....	30
4.1.1. Kontrast Sonrası 30.sn. T1 Ağırlıklı Kesitlerinin Analizi.....	30
4.1.2. Kontrast Sonrası 70.sn. T1 Ağırlıklı Kesitlerinin Analizi.....	33
4.1.3. T2 Kesitlerinin Analizi.....	36
4.1.4. SPAIR T2 Kesitlerinin Analizi .....	39
4.1.5. Dış Faz (out of phase) Kesitlerinin Analizi .....	41
4.1.6. ADC Kesitlerinin Analizi .....	43
4.2. NÜKLEER GRADE-TEKSTÜR ÖZELLİKLERİ İLİŞKİSİNİN DEĞERLENDİRİLMESİ.....	45
<b>5. OLGU ÖRNEKLERİ.....</b>	<b>49</b>
<b>6. TARTIŞMA.....</b>	<b>52</b>
<b>7. SONUÇ.....</b>	<b>58</b>
<b>8. KAYNAKLAR .....</b>	<b>59</b>

## TABLO LİSTESİ

<b>Tablo 1.</b>	Histogram analizinde sıklıkla incelenen parametreler.....	9
<b>Tablo 2.</b>	COM Analizinde sıklıkla incelenen parametreler. ....	10
<b>Tablo 3.</b>	Tekrar Uzunluğu Matrisi (Run Length Matrix, RLM) Analizi ilişkili sık kullanılan parametreler sıralanmıştır.....	11
<b>Tablo 4.</b>	WHO 2016 Sınıflamasına göre böbrek tümörlerinin gösterimi. ....	17
<b>Tablo 5.</b>	WHO 2016 Sınıflamasına göre RHK alt-tipleri ve genel özellikleri gösterilmektedir.....	18
<b>Tablo 6.</b>	Çalışılan tüm sekanslar için ayırt edici özellikler ve diskriminant analizi sonucunda orijinal gruplara göre doğru sınıflanan olguların oranları gösterilmiştir.....	29
<b>Tablo 7.</b>	Kontrast sonrası 30.sn. T1 ağırlıklı görüntüler için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir. ....	30
<b>Tablo 8.</b>	Kontrast sonrası 30.sn. T1 ağırlıklı görüntülere ait değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir. ....	31
<b>Tablo 9.</b>	Kontrast sonrası 30.sn. T1 ağırlıklı görüntülere ait kanonik diskriminant analiz ile oluşturulan her fonksiyon için formüller gösterilmektedir.....	31
<b>Tablo 10.</b>	Kontrast sonrası 30.sn. T1 verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.....	33
<b>Tablo 11.</b>	Kontrast sonrası 70.sn T1 ağırlıklı görüntüler için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir. ....	33
<b>Tablo 12.</b>	Kontrast sonrası 70.sn. T1 ağırlıklı görüntülere ait değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.....	34
<b>Tablo 13.</b>	Kontrast sonrası 70.sn. T1 ağırlıklı görüntülere ait kanonik diskriminant analiz ile oluşturulan her fonksiyon için formüller gösterilmektedir.....	35
<b>Tablo 14.</b>	Kontrast sonrası 70.sn. T1 verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.....	36
<b>Tablo 15.</b>	T2 ağırlıklı görüntüler için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.....	37
<b>Tablo 16.</b>	T2 verileri için belirlenen fonksiyonlara göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.....	38



<b>Tablo 17.</b>	T2 verilerinin üç ayrı gruba göre sınıflama sonuçları gösterilmektedir.....	39
<b>Tablo 18.</b>	SPAIR T2 görüntüler için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.....	39
<b>Tablo 19.</b>	SPAIR T2 verileri için belirlenen fonksiyonlara göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.....	40
<b>Tablo 20.</b>	SPAIR T2 verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.....	41
<b>Tablo 21.</b>	Dış faz görüntülerde kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.....	41
<b>Tablo 22.</b>	Dış faz kesitlerine ait veriler için belirlenen fonksiyonlara göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.....	42
<b>Tablo 23.</b>	Dış faz verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.....	43
<b>Tablo 24.</b>	ADC kesitleri için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.....	43
<b>Tablo 25.</b>	ADC kesitleri için belirlenen fonksiyonlara göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.....	44
<b>Tablo 26.</b>	ADC verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.....	45
<b>Tablo 27.</b>	Berrak hücreli RHK olgularının cinsiyet ve Fuhrman nükleer evresine göre listesi.....	46
<b>Tablo 28.</b>	Berrak hücreli RHK olgularının düşük grade-yüksek grade ayırımına yönelik kanonik diskriminant analiziyle belirlenen kontrast sonrası 70.sn. T1 ağırlıklı, T2 ağırlıklı ve ADC görüntüleri için fonksiyonların özdeğer verileri listelenmiştir.....	46
<b>Tablo 29.</b>	Düşük evre-yüksek evre ayırımına yönelik her üç sekans için belirlenen fonksiyona göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.....	47
<b>Tablo 30.</b>	Nükleer evre ilişkisine yönelik Kanonik Diskriminant Analizi ile ADC, T2 ve kontrast sonrası 70.sn. T1, sekanslarında oluşturulan fonksiyonlara ait formüller gösterilmektedir.....	48
<b>Tablo 31.</b>	Düşük nükleer evre – yüksek nükleer evre verilerinin üç ayrı sekansta sınıflama sonuçları gösterilmektedir.....	48

## ŞEKİL LİSTESİ

Şekil 1.	Tekstür analizi süreci basamakları gösterilmektedir.....	4
Şekil 2.	SPAIR T2 aksiyel görüntüde sol parotis bezindeki kitlenin tekstür analizi için farklı ROİ yöntemleri kullanılarak yapılan seçimleri izlenmektedir. ....	6
Şekil 3.	Aksiyel düzlemde boyun SPAIR T2 MR kesiti.....	6
Şekil 4.	Aksiyel düzlemde boyun SPAIR T2 kesitinin farklı interpolasyon metotları ile oluşturulmuş piksel büyütme gösterilmekte. ....	7
Şekil 5.	Aksiyel SPAIR T2 boyun MR kesitinin farklı piksel derinliklerindeki MR görüntüleri izlenmektedir.....	8
Şekil 6.	Eş-dizilim Matrisi “Co-occurrence Matrix” (COM) analizinin gösterimi.....	10
Şekil 7.	Tekrar-uzunluğu matrisi “Run-length Matrix” (RLM) analizinin gösterimi.....	11
Şekil 8.	Homojen bir tekstür .....	12
Şekil 9.	Dalgacık Transformasyonunun şematik görüntüsü. ....	13
Şekil 10.	Kontrast sonrası 30.sn. T1 ağırlıklı görüntü değişkenlerinin sınıflama sonuçlarına ait grafik. ....	32
Şekil 11.	Kontrast sonrası 70.sn. T1 ağırlıklı görüntülerinin sınıflama sonuçlarına ait grafik.....	35
Şekil 12.	T2 Verilerinin analizine ait grafikler izlenmektedir. ....	38
Şekil 13.	SPAIR T2 görüntülerinin sınıflama sonuçlarına ait grafik. ....	40
Şekil 14.	Dış faz görüntülerinin sınıflama sonuçlarına ait grafik. ....	42
Şekil 15.	ADC görüntülerinin sınıflama sonuçlarına ait grafik .....	44
Şekil 16.	Berrak hücreli RHK olgusunun sağ böbrek alt kesim anteriorunda 61x58mm boyutlu lezyon izlenmektedir.....	49
Şekil 17.	Kromofob RHK olgusunun sağ böbrek üst kesim lateralindeki 42x35mm boyutlu lezyon izlenmektedir.....	50
Şekil 18.	Onkositom olgusunun sol böbrek orta kesim posteriyordaki 30x32mm boyutlu lezyon izlenmektedir.....	51

## ÖZET

**Amaç:** Radyolojik görüntüleme yapı çözümü uygulaması tekstür analiz bulgularının böbrek kitlelerinden renal hücreli karsinoma (RHK) ve onkositom ayırıcı tanısındaki etkinliğini, RHK alt tiplerini sınıflamadaki katkısını ve RHK nükleer evresi ile ilişkisini araştırmaktır.

**Gereç ve yöntem:** Etik kurul onayı sonrası retrospektif olarak Kasım 2016- Kasım 2018 tarihleri arasında böbreklere yönelik manyetik rezonans (MR) görünülmesi yapılmış olan ve parsiyel ya da total nefrektomi sonrası patolojik tanısı bulunan 32 olgu (24 erkek, sekiz kadın; ortalama yaş 60) dahil edildi. Olgular patolojik tanılarına göre gruplara ayrıldı (21 berrak hücreli renal hücreli karsinom (RHK), beş papiller RHK, üç kromofob RHK, üç onkositom; 21 berrak hücreli RHK olgusunun 10'u düşük evre, 10'u yüksek evre). Tekstür özellik seçimi ve çıkarımı işlemleri MaZda yazılımı kullanılarak T2 Ağırlıklı, SPAIR T2 Ağırlıklı, ADC, dış faz ile kontrast sonrası 30.sn. T1 ve 70.sn. T1 Ağırlıklı görüntülerde 2B aksiyel görüntüler üzerinde uygulandı. Özellik seçimi için Fisher katsayısı ve POE+ACC yöntemleri kullanıldı. Seçilen özellikler kanonik diskriminant analizi ile SPSS 25 programı kullanılarak analiz edildi.

**Bulgular:** Yöntemin, farklı sekanslara ait görüntüler kullanıldığında RHK alt gruplarını birbirinden ve onkositomdan ayırmadaki başarısı farklı bulundu. T2 Ağırlıklı ve kontrast sonrası 70.sn. T1 Ağırlıklı görüntüler üzerinde yapılan değerlendirmede olguların %100'ü doğru sınıflandırıldı. SPAIR T2 Ağırlıklı görüntülerinden olguların %89,3'ü, ADC görüntülerinde %75,9'u, dış faz görüntülerinde %93,3'ü ve kontrast sonrası 30.sn. T1 Ağırlıklı görüntülerinde %95'i doğru sınıflandığı görüldü. Berrak hücreli RHK olgularında düşük evre - yüksek evre ayırımında kullanılan sekanslardan ADC ve kontrast sonrası 70.sn. tekstür verilerine göre olguların tamamı doğru sınıflandı. T2 ağırlıklı görüntülerdeki tekstür özellikleriyle ise olguların %93,8'i doğru evreye sınıflanabildi.

**Sonuç:** MR görüntülerinde RHK'yi onkositomdan ayırmada, RHK alt tiplerini sınıflandırmada, ve berrak hücreli RHK nükleer evresini ayırt etmede tekstür temelli analiz parametreleri kullanılabilir.

**Anahtar kelimeler:** Radyolojik görüntüleme yapı çözümü, tekstür analizi, MaZda, böbrek kitleleri, renal hücreli karsinom, onkositom

## ABSTRACT

**Aim:** The purpose is to investigate texture analysis findings', the structure analysis application in radiological imaging, efficacy in the differential diagnosis of kidney masses renal cell carcinoma (RCC) and oncocytoma, contribution to the classification of RCC subtypes and relationship with the nuclear stage of RCC.

**Materials and Methods:** After the approval of ethics committee, retrospectively 32 patients (24 males, eight females; mean age of 60 years) who underwent renal magnetic resonance (MR) imaging between November 2016 and November 2018, having pathological diagnosis either after partial or total nephrectomy were included. The cases were divided into groups according to their pathological diagnoses (21 clear cell RCC, five papillary RCC, three chromophobe RCC, three oncocytoma; out of 21 clear cell RCC cases 10 were low stage, 10 were high stage). Texture feature selection and extraction processes were applied on 2D axial images of T2 Weighted, SPAIR T2 Weighted, ADC, out-of-phase, 30 sec and 70 sec contrast enhanced T1 Weighted images using the MaZda software. Fisher's coefficient and POE + ACC methods were used for feature selection. The selected features were analyzed with canonical discriminant analysis by using SPSS 25 software.

**Result:** The success rate of the method in distinguishing the RCC subtypes from each other and from oncocytoma were found to be different, when images of different sequences were used. With the evaluation on T2 Weighted and 70 sec contrast enhanced T1 Weighted images, 100% of the cases were classified correctly. On SPAIR T2 Weighted images 89.3% of the cases, on ADC images 75.9% of the cases, on out-of-phase images 93.3% of the cases and on 30 sec contrast enhanced T1 Weighted images 95% of the cases were seen to be classified correctly. All of the cases were classified correctly according to the data on ADC and 70 sec contrast enhanced T1 Weighted images, the sequences which were used in distinguishing between low stage and high stage of clear cell RCC cases. According to the data on T2 Weighted images 93.8% of the cases could be classified correctly.

**Conclusion:** Texture based analysis parameters can be used on MR images in differentiating RCC from oncocytoma, in classifying the RCC subtypes, and in discriminating clear cell RCC nuclear stage.

**Key words:** Structure analysis on radiological imaging, texture analysis, MaZda, renal masses, renal cell carcinoma, oncocytoma

# 1. GİRİŞ VE AMAÇ

Lezyonların ayırıcı tanısının minimal invaziv yöntemlerle yapılabilmesi günümüz radyolojisinin üzerinde çok fazla çalışmalar yapılan önemli araştırma alanlarından biridir. İnvaziv yöntemlerin hasta konforuna olumsuz etkileri, kanama, enfeksiyon gibi çeşitli komplikasyonları invaziv olmayan tanı yöntemleri arayışına yönlendirmektedir. Lenf nodlarında ve böbreklerde olduğu gibi pek çok lezyonun tanısında ilgili organın parsiyel veya komplet eksizyonu gerekebilmektedir. Geri dönüşü olmayan bu işlem sonrasında lezyonlar patolojik olarak benign tanılar da alabilmektedir (1). Bu durum invaziv olmayan tanı yöntemleri arayışının ne denli önemli olduğunun bir göstergesidir.

Farklı doku ve lezyonların iç yapısındaki heterojeniteye karşılık gelen bulgular radyolojik görüntülerine de yansımaktadır. Gözle görebildiğimiz ötesindeki bu değişiklikleri göstermek için kullanılan yöntemlere tekstür analizi olarak bilinmektedir (2). Doku yapısal özelliklerini göstermeye olanak sağlayan tekstür analizi ile ilgili çeşitli alanlarda yapılan çalışmalar lezyonların invaziv olmadan benign-malign ayrımında, tanısının konmasında, histopatolojik evresini değerlendirmede umut verici sonuçlar vermektedir. Çeşitli alanlardaki bu çalışmalar tekstür verileri ile patolojik bulguların korele olduğunu göstermektedir (3-5).

Bu çalışmada radyolojik görüntüleme yapı çözümlene uygulamalarından tekstür analizi kullanarak değerlendirmek üzere seçilen böbrek kitlelerinin görülme sıklığı görüntüleme yöntemlerindeki teknolojik gelişmeler ve bu yöntemlerin kullanımındaki sıklığa paralel olarak son yıllarda giderek artmıştır (6,7). Böbrek kitlelerine uygun klinik yaklaşım için lezyonların benign-malign ayrımının yapılabilmesi, onkolojik yaklaşımın seçilebilmesi için malign lezyonların karakterizasyonu ve alt tiplerinin belirlenmesi çok önemlidir (8). Bu bağlamda, gereksiz biyopsi ve cerrahi rezeksiyon sayılarını azaltmaya yönelik olarak invaziv olmayan tanı ve takip yöntemlerinin arayışı vardır.

Bu çalışmada amaç, i) radyolojik görüntüleme yapı çözümlene uygulamalarından tekstür analizi kullanarak manyetik rezonans görüntüleme ile elde

edilen görüntülerdeki tekstür özelliklerinin renal hücreli karsinom ve onkonsitom ayırıcı tanısındaki yeri, ii) renal hücreli kanserin alt tiplerini sınıflamadaki katkısı ve iii) berrak hücreli RHK lezyonlarının nükleer evreleri ile tekstür özellikleri arasındaki ilişkiyi arařtırmak olmuřtur.



## 2. GENEL BİLGİLER

### 2.1. DOKU YAPISAL ANALİZİ

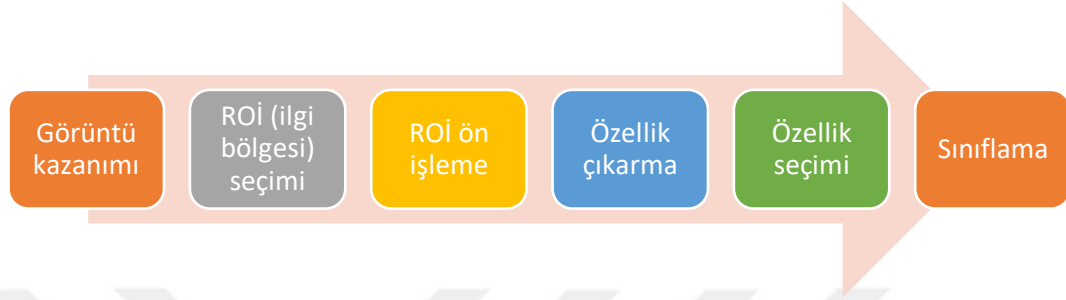
Radyolojik görüntüleme yöntemleri, gelişen teknolojiler ile birlikte lezyonların tanınmasında, ayırıcı tanıların yapılabilmesinde, patolojiye yol göstermede vazgeçilemez bilgiler sağlamaktadır. Beraberinde bu görüntüleme yöntemleri gözümüz ile saptayabileceğimizden çok daha fazla bilgiyi de içlerinde barındırmaktadır (2). Farklı doku ve lezyonların iç yapısındaki heterojeniteyi gözle görebilmek mümkün değildir. İnsan gözünün saptayabileceğinin ötesindeki değişiklikleri ortaya koymak üzere çeşitli yöntemler geliştirilmiştir (2).

Tekstür “Herhangi bir dokuyu belirleyen kendine özgü yapı, doku örgüsüdür” (9). tipik olarak nesne yüzeylerinin pürüzlüğünden kaynaklanan karakteristik yoğunluk (veya renk) değişimleridir (10). Görüntülemelerde tekstür için kararlaştırılmış net bir tanım olmamakla birlikte piksel yoğunluklarının uzaysal farklılıkları olarak ifade edilir (11). Dokudaki yoğunluk değişimleri düzenlilikler ve rastgelelikler sergilemektedir. Bu dokusal özellikler arasındaki ilişkileri, değişiklikleri modelleme, sınıflama ve bölümlere ayırarak istatistiksel ve yapısal metotlarla değerlendirme işlemine “tekstür analizi” denmektedir (10). Tekstür analizi bir doku hakkında gözümüzle göreceğimiz ötesinde bilgileri sağlayabilir. Görüntü üzerinde piksel farklılıklarının katkısıyla oluşan heterojenitenin niceliksel ve niteliksel olarak gösterilmesine olanak sağlar (2). Görüntülemelerde tekstür analizi, gri spektrumunun niceliksel değerlendirilmesi ve pikseller arası ilişkiyi ortaya koyan bir çok tekniği barındırır.

Tekstür analizi ile ilgili değerlendirmeleri içeren yöntemlerle ilişkili örnekler ilk olarak 1970’li yıllarda tanımlanmaya başlamıştır (12,13). Hawkins, tekstür kavramının bağlı olduğu üç bileşeni; “Bazı küçük alanlardaki düzen "order" büyük örneklem üzerinde tekrarlanmalara sahiptir.” “Düzen "order" temel parçaların rasgele olmayan düzenlenmesinden oluşur.” “Aynı düzlemdeki tekstür içerisindeki parçalar kabaca tekdüze "uniform" düzendedir.” şeklinde ifade etmiştir (13).

### 2.1.1. Tekstür Analizi Süreci

Tekstür analizi temel olarak görüntüleme disiplinlerinden sınıflama, segmentasyon ve sentez işlemlerini kullanır (11). Tekstür analiz işlemi 6 basamaklı bir işlemdir (Şekil 1);



Şekil 1. Tekstür analizi süreci basamakları gösterilmektedir.

#### 2.1.1.1. Görüntü kazanımı

Bir lezyonun doku kontrast farklılığı, bir anlamda heterojenitesi, bilgisayarlı tomografi’de (BT), manyetik rezonans (MR) görüntülerinde ya da ultrasonografi’de (US) görüntüye farklı yansıyacaktır. Bu nedenle farklı yöntemlerle elde edilen görüntülerde doku tekstür özelliklerinin kendi içlerinde ayrı ayrı değerlendirilmesi gerektiği ifade edilir

Görüntüleme yöntemlerinde kullanılan farklı parametreler, farklı sekanslar, farklı kesit kalınlıkları vb. de farklı tekstür yapılarına neden olur. Dolayısıyla tekstür analiz işleminin sonucu görüntü oluşturulma metodundan etkilenir (2,14). Ancak bu durum farklı cihazlarda farklı protokollerle elde edilmiş görüntülerin birlikte değerlendirilemeyeceği anlamına da gelmemektedir (2,15).

Tüm görüntüleme yöntemlerinde sinyal-gürültü oranı ve uzaysal çözünürlük tekstür sonuçlarını etkileyen en önemli faktörlerdir (16). Gürültü basitçe, homojen bir fantomda voksel değerlerinin standart sapması olarak tanımlanır (17). BT incelemelerinde kVp (kilovolt potansiyel), mA(miliamper), expojur süresi, kesit kalınlığı, pitch değeri gibi faktörler sinyal gürültü oranını etkileyebilir. MR incelemelerinde manyetik alanın gücü, voksel volümü, tekrarlama zamanı (TR: time




to repeat), eko zamanı (TE: time to echo), flip angle, görüntüyü oluşturmak için faz adımlarının kaç kere tekrarlandığı (NEX: Number of excitation ya da NSA: Number of Signal Averaged), sargı tipi gibi pek çok neden sinyal-gürültü oranını etkileyebilir (18). Dolayısıyla bu faktörlerin tekstür sonuçlarına etkilerinin olacağını söylemek mümkündür. BT'de kullanılan farklı filtreleme metotlarının, iterative rekonstrüksiyon uygulamasının tekstür verilerini etkilediği gösterilmiştir (19–21). Yine tüm görüntülemelerde hareket kaynaklı olanlar başta olmak üzere çeşitli artefaktlar tekstür analizi sonuçlarını etkileyebilmektedir.

Bununla birlikte, yeterli uzaysal çözünürlük sağlandığında bu parametrelerin etkilerinin çok ciddi olmadığı fantomlar kullanılarak yapılan bir çalışmada gösterilmiştir (16). Yine aynı çalışmada uzaysal çözünürlüğün düşük olduğu durumlarda, ileride bahsedilecek olan tekstür analiz metotlarından co-occurrence matrix (COM) sonuçlarının bu durumdan daha az etkilendiği gösterilmiştir (16). Yanı sıra, yukarıda bahsi geçen faktörlerin tekstür analizine etkilerinin göz ardı edilebilecek düzeylerde olduğunu belirten çok merkezli çalışmalar da bulunmaktadır (2,22,23).

### **2.1.1.2. İlgi bölgesi (Region of interest- ROİ) seçimi:**


İlgi bölgesi (ROİ) seçimi çeşitli metotlarla yapılabilir. Bu seçim uygulamaya göre farklılık gösterir. Tekstür analizinin uygulanacağı veri tipine göre 2 boyutlu veya 3 boyutlu bir ROİ seçilebilir. ROİ seçilirken genellikle lezyon sınırlarının tümünü içine alan bir dikdörtgen veya daire ya da lezyon içinden bir alanı örnekleyen bir dikdörtgen veya daire çizilir. İlk ölçüm yönteminde lezyon dışındaki alanların tekstür analizi verilerini etkileyeceği, ikinci ölçüm metodunda ise lezyonun tümü görüntüleme alanında olmadığından sadece belli bir kısmının analiz edilebileceği bu nedenle tekstür analiz sonuçlarının değişebileceği anlaşılmaktadır. Bu nedenle en uygun ROİ seçiminin manuel olarak lezyon konturlarından çizilen bir ROİ olduğu belirtilmektedir (Şekil 2) (2,24,25). ROİ büyüklüğü de tekstür analizini etkiler. ROİ boyutları arttıkça tekstür analizi sonuçları daha anlamlı olur. ROİ en az içerisinden tekstür verisi alınabilecek büyüklükte olmalıdır (2,26). 80x80 pikselin altındaki alandan yapılan ölçümlerin analiz sonuçlarını etkileyeceği belirtilmekte ve en az 180x180 piksellik bir alandan ölçüm yapılması önerilmektedir (2).



**Şekil 2.** SPAIR T2 aksiyel görüntüde sol parotis bezindeki kitlenin tekstür analizi için farklı ROİ yöntemleri kullanılarak yapılan seçimleri izlenmektedir.

(A)'da lezyondan taşan dikdörtgen ROİ, (B)'de lezyonun içinden belli bir kesimi örnekleyen daha küçük dikdörtgen ROİ, (C)'de manuel olarak çizilmiş lezyonun tüm sınırlarını içine alan ROİ izlenmektedir.

Ayrıca piksel sıklığı seçilerek istenen analiz metodu özelliğine göre seçilen ROİ'nin özellik haritaları oluşturulabilir. İncelenen dokuda gözle görülemeyecek özellikler bu şekilde görselleştirilebilir (Şekil 3) (2).




**Şekil 3.** Aksiyel düzlemde boyun SPAIR T2 MR kesiti

(A) farklı doku analiz yöntemleri ile tekstür özelliklerinin görsel olarak gösterimi izlenmektedir. (B)'de histogram temelli, (C)'de Run Length Matrix (RLM) özelliklerine, (D)'de Aksiyel Co-occurrence matrix (COM) özelliklerine göre oluşturulmuş bir haritasını görmekteyiz.

### 2.1.1.3. ROİ ön işleme

Farklı protokollerin farklı cihazların etkilerini azaltmak için bazı ROİ ön işleme yöntemleri geliştirilmiştir. Bu işlemlerin amacı analiz edilecek ROİ'leri aynı duruma getirmek, tekstür özelliklerini belirginleştirmektir (2).

**a. İnterpolasyon:** Kısaca boşluk doldurma olarak tanımlayabileceğimiz interpolasyon işlemi lineer, kübik, b-spline, zero-fill gibi çeşitli metotlarla tekstür analizi öncesinde kullanılabilir (Şekil 4) (2,27). Bu işlem ile matris boyutu artırılarak tekstür özelliklerini belirgin hale getirilebilir. Özellikle 3 boyutlu veriden analiz yapılacağı durumlarda kesit kalınlığından kaynaklanan sorunları çözmek için interpolasyon yöntemleri daha önemli hale gelmektedir (2).



**Şekil 4.** Aksiyel düzlemde boyun SPAIR T2 kesitinin farklı interpolasyon metotları ile oluşturulmuş piksel büyütme sonuçları gösterilmektedir.

(A)'da 90x100 piksellik gerçek MR kesitinin (B)'de nearneighbour, (C)'de lineer, (D)'de kübik interpolasyon metotları kullanılarak yapılan büyütme sonuçları izlenmektedir.

**b. Normalizasyon:** Yapılan çalışmalar farklı görüntülerdeki ortalama intensitenin ve intensite farklılıklarının da tekstür analizi sonuçlarını etkilediğini göstermiştir. Farklı görüntüler arasındaki bu intensite farklılıklarını birbiriyle uyumlu hale getirmek için birçok normalizasyon metodu üzerinde çalışılmıştır (2,28,29). Bu normalizasyon metotlarından en sık kullanılanı “ $\mu \pm 3\sigma$ ” normalizasyon metodudur. Bu yöntemde  $\mu$  ortalama grilik değerine,  $\sigma$  grilik değerinin standart sapmasına karşılık gelmektedir (2).

**c. İnhomojenite ve artefakt düzeltme:** ROİ çizilerek değerlendirilecek alan ROİ çizilmeden önce artefaktsız olarak elde edilmelidir. Artefaktlar doğrudan tekstür

yapısının yanlış algılanmasına neden olacağı için 2 boyutlu incelemelerde artefaktsız kesitler tercih edilmelidir. Bu nedenle görüntü kazanımı sürecinde artefaktsız görüntü elde edilmeye çalışılmalıdır.

Görüntüde sinyal her zaman görüntünün her kesiminde uniform bir şekilde izlenmeyebilir. *İnhomojenite* olarak tanımlayabileceğimiz bu durum BT’de daha çok görüntünün santral kesiminin daha dens olması şeklinde izlenirken, MR’da statik manyetik alan homojenitesini bozan başta koil kaynaklı parlamalar ile karşımıza çıkmaktadır (2,30,31). Günümüzde çeşitli algoritmalar görüntü kazanımından sonra inhomojeniteyi düzeltmek için kullanılmaktadır. Bu algoritmalarından en bilineni “nonparametric non-uniform intensity normalization” N3 olarak bilinen algoritmadır (2,32,33).

**d. Grilik değerinin belirlenmesi:** Görüntülemeadaki grilik değeri, pikseldeki sayısal derinlikle ilişkilidir. Örneğin 8 bitlik bir görüntüde  $2^{10}=1024$  grilik değeri bulunacaktır. Grilik değerinin aralığının büyüklüğü daha sonra bahsedeceğimiz matris temelli tekstür analizi metotlarının başarısını etkiler (2). Bu testler genelde 16,32,64,128,256’lık grilik değerleriyle işlenir (Şekil 5) (2).



**Şekil 5.** Aksiyel SPAIR T2 boyun MR kesitinin farklı piksel derinliklerindeki MR görüntüleri izlenmektedir.

Aynı MR kesitinin (A)'da 8bit, (B)'de 4bit, (C)'de 1bit görüntüleri gösterilmiştir.

#### 2.1.1.4. Özellik çıkarımı

ROI seçildikten sonra sıra tekstür analiz işlemlerine gelmektedir. Çeşitli tekstür analiz metotları literatürde tanımlanmıştır (2,10,34). Tekstür analiz metotları genellikle yapısal, istatistiksel, model-temelli ve transform yöntemleri olarak sınıflandırılmaktadır (35).

##### 2.1.1.4.1. İstatistiksel yöntemler

Görüntüdeki grilik değerlerinin dağılımını, birbirleriyle ilişkilerini kullanan analiz metotlarıdır (34). Birinci derece “first-order” istatistiksel analiz metotları tek piksel verisi kullanarak değerlendirme yapan piksel ilişkilerine bakmayan bir değerlendirme yöntemlerini kapsar. Bu metotlar daha çok diğer tetkikler ile birlikte kullanılır. Yapının tekstür özelliklerini göstermede doğrudan yarar sağlamaz (2,34,35).

**a. Histogram analizi:** Histogram temelli parametreler en sık kullanılan birinci derece istatistiksel parametrelerdir. Histogram analizinde sıklıkla değerlendirilen parametreler Tablo 1’de özetlenmiştir (36).

**Tablo 1.** Histogram analizinde sıklıkla incelenen parametreler.


Ortalama değer “mean”	Görüntüdeki piksellerin grilik değerlerinin ortalamasını ifade eder.
Varyans “Variance”	Görüntüdeki bütün grilik değerlerinin ortalama değere olan uzaklıklarının ortalamasıdır
Çarpıklık “Skewness”	Ortalamaya her iki yönde uzaklığı ifade eder. Çarpıklığın pozitif olması sayı olarak ortalamanın altında daha fazla değer olduğunu, çarpıklığın negatif olması ortalamanın üstünde daha fazla değer olduğunu ifade eder.
Basıklık “Kurtosis”	Değerlerin dağılımının ne kadar yatay olduğunu ifade eder. Piksel değerlerinin ne miktarda tek tip olduğunun bir göstergesidir.

**b. Co-occurrence matrix (COM, Eş-dizilim matrisi):** Haralick ve ark.’nın tanımladığı şekliyle Gri-ton Uzaysal Bağımlılık Matrisi “Gray-Tone Spatial-Dependence Matrices” ya da günümüzde yaygın kullanılan şekliyle eş-dizilim matrisi görüntüleme piksel çiftlerinin dağılımını analiz ederek istatistiksel bilgi sağlar (Şekil 6). Piksel çiftlerinin sayımı daha önceden belirlenen mesafede ve

yönlerde yapılır (2,37). Eş-dizilim matrisi ikinci derece istatistiksel bir metottur (38). Bu testin en önemli dezavantajı yönden etkilenmesidir. Seçilen görüntü hafif rotasyona uğradığında bile piksel çiftlerinin ilişkisi ve dağılımı değişecektir. Bu sorun ölçümlerin tüm yönde yapılması ile aşılabılır (2,36,38). COM analizi ile sıklıkla değerlendirilen parametreler Tablo 2’de özetlenmiştir (36,38).

**Tablo 2.** COM Analizinde sıklıkla incelenen parametreler.


Enerji veya ikincil açısal moment “second angular moment”	Değerlendirilen alanın homojenliğini gösterir yüksek enerji değeri daha homojen bir görüntüye karşılık gelir.
Kontrast “Contrast”	Lokal varyasyonların miktarıdır.
Korelasyon “Correlation”	Görüntüdeki gri değerlerinin lineer bağımlılığını ölçer.
Karelerin toplamı “Sum of squares”	Varyansın eş-dizilim analizindeki karşılığıdır.
Ters farklı Moment “Inverse difference moment”	Homojenitenin farklı bir gösterim şeklidir.
Ortalamanın toplamı “Sum average”	İlgilenilen görüntüdeki ikili piksellerin değerinin toplamının ortalamasını verir.
Varyansın toplamı “Sum variance”	Sum average kullanılarak üretilen bir parametredir.
Entropi “Entropy”	Görüntünün düzensizliğini gösterir. Tüm çiftlerin sayısı eşit olduğunda entropi en yüksek değerini alır.
Varyans farklılığı “Difference variance”	İki piksel temel olarak varyans farklılıklarının gösterimidir.
Entropi farklılığı “Difference entropy”	İki piksel temel olarak entropi farklılıklarının gösterimidir.
Entropi toplamı “Sum entropy”	Diğer sum incelemelerindeki gibi ikili entropilerin toplamlarının ortalamasıyla belirlenir.



**Şekil 6.** Eş-dizilim Matrisi “Co-occurrence Matrix” (COM) analizinin gösterimi.

(A)'da gösterilen 4bit'e indirgenmiş MR kesitinde kırmızı ile taralı alanın piksel-piksel grilik değerleri (B)'de gösterilmiştir. (C)'deki tabloda (B)'de gösterilen grilik değerlerinin sayısal gösterimi ve çiftlerin nasıl seçildiği örneklenmiştir. (D)'deki tablo tüm piksel çiftlerinin sayımını göstermektedir.

c. **Tekrar-uzunluğu matrisi “Run-length Matrix” (RLM):** Daha karmaşık bir dokuda göreceli olarak daha uzun grilik-değeri tekrarları olacaktır. Daha homojen bir dokuda ise göreceli olarak daha kısa grilik-değeri tekrarları olacaktır (39). Bu piksellerdeki belirlenen grilik-değerleri tekrarlarının belirli bir yönde sayıldığı yöntem “tekrar-uzunluk matrisi” olarak bilinmektedir (Şekil 7) (36). Doku hakkında yüksek-dereceli istatistiksel bilgi sağlar.



**Şekil 7.** Tekrar-uzunluğu matrisi “Run-length Matrix” (RLM) analizinin gösterimi.

(A)'da gösterilen kırmızı ile taralı 5x5 piksellik alanın (B)'de grilik değerleri gösterilmiştir. (C)'deki tabloda grilik değerlerinin sayısal gösterimi ve grilik değeri 3 olan piksellerin ikili tekrarları gösterilmiştir. (D)'deki tablo tüm piksel değerleri için uzunluk değerlerini göstermektedir.

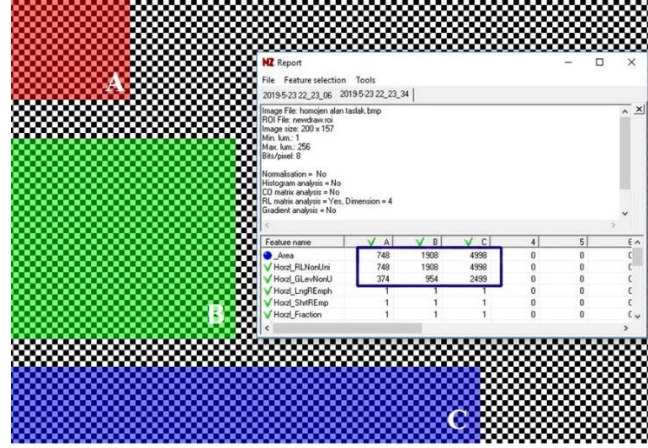
*Tekrar-uzunluğu matrisi* ile analiz edilebilen veriler Tablo 3'te listelenmiştir. Bu yöntemde de veriler testin güvenilirliğini arttırmak için farklı yönlerde çalışılabilir (36).

**Tablo 3.** Tekrar Uzunluğu Matrisi (Run Length Matrix, RLM) Analizi ilişkili sık kullanılan parametreler sıralanmıştır.

Long run emphasis ve Short run emphasis :	Uzun ve kısa tekrarların oranları hakkında bilgi verir.
Gray level nonuniformity	Grilik-seviyesi tekrarlarının ne kadar düzensiz (nonuniform) dağıldığını gösterir. Grilik değeri tekrarı tek tipe yakınsa daha küçük bir değer alır.
Run length nonuniformity	Tekrar uzunlukları arasındaki gri değerlerin dağılımını ölçer.
Fraction	Tanımlanan matristeki mevcut herhangi bir çalışmanın parçası olan görüntü piksellerinin oranını tanımlar.

Tekrar uzunluğu matrisi parametrelerinden grilik-değeri düzensizliği “Gray-level nonuniformity” ve tekrar uzunluğu düzensizliği “Run-length nonuniformity” ROİ büyüklüğü ile doğrudan ilişkilidir (Şekil 8). Bu nedenle piksel sayısı ile korele bir normalizasyon faktörü ile birlikte kullanılmalıdır (2,26).





**Şekil 8.** Homojen bir tekstür

Kırmızı ile taralı (A), yeşil ile taralı (B), mavi ile taralı (C) alanlarının tekstürleri homojen olduğu halde Tekrar Uzunluk Matrisi parametrelerinden grilik-seviyesi düzensizliği (Horz\_LGLevNonU) ve tekrar-uzunluğu düzensizliği (Horz\_RLNonUni) parametrelerinin ROI boyutundan etkilenişi ve tekstürlerin aynı olmasına rağmen değerlerin farklı oluşu gösterilmektedir.

#### 2.1.1.4.2. Model-temelli yöntemler

Model temelli yöntemler, fraktal olarak bilinen generatif bir imaj modeli ya da rastlantısal bir model kullanarak dokuyu analiz etmeye çalışır (2). Bu yöntemlerin matematiksel karmaşıklıkları nedeniyle daha az kullanılır.


**a. Otoresgressif model:** Rastlantısal bir modeldir. Sonucun lineer yönde kendinden önceki verilere ve mükemmel olmayan rastgele bir veriye bağlı olduğunu varsayan bir modeldir. Görüntülemde imaj pikselleri arasında lokal etkileşim olduğunu varsayar ve her bir pikselin gri-seviyesi değerini komşu değerlerin ağırlıklı toplamı şeklinde tanımlar (2,36). Daha basit bir ifade ile tanımlamak gerekirse komşu piksel ilişkilerini inceleyerek görüntüdeki şekilleri saptamaya yarar (34). Komşu piksellerin katsayısını gösteren teta(Theta,  $\theta$ ) değerleri ve standart gürültü hatası (Sigma,  $\sigma$ ) hesaplanabilir (36,40).

#### 2.1.1.4.3. Dönüşüm-temelli yöntemler

Görüntüdeki tekstür özellikleri başka bir frekans ya da ölçek alanı gibi farklı bir türe dönüştürülerek analiz edilir (34).



**a. Dalgacık dönüşümü (Wavelet transformation):** Dalgacık dönüşümü frekans temelli bir dönüşüm modelidir. Tek boyutlu bir sinyal düşünüldüğünde sinyalin zamanla çok hızlı değişiyorsa yüksek frekanslı, yavaş değişimler gösteriyorsa düşük frekanslı olarak tanımlanır (34). Aynı şekilde iki boyutlu bir görüntüde de grilik değerleri arasındaki değişiklikler çok fazlaysa bu görüntünün yüksek frekanslı olacağını düşünebiliriz (34). Görüntünün ölçeği bu frekans değişimini doğrudan etkiler. US ile incelenen bir meme lezyonunu düşünecek olursak; görüntüleme penceresinin derinlik ayarı 4cm'e ayarlandığında 10cm'e göre ayarlandığından çok daha fazla ayrıntı içerecektir ve değişim frekansı daha yüksek olacaktır. Ayrıca yine yönünde frekans değişimi değerlerini etkileyeceği, farklı yönlerde farklı frekans değişikliklerinin olacağı aşikardır. Dalgacık dönüşümü ile farklı ölçeklerde ve farklı yönlerde dalgacık katsayıları (Wavelet Coefficients) elde edilir (Şekil 9). Bir görüntünün dalgacık dönüşümü hesaplanırken, her bir piksele görüntünün o noktadaki frekans içeriğini bir ölçekler kümesi üzerinde karakterize eden bir sayı kümesini (dalgacık katsayıları) ilişkilendirilir (34).



**Şekil 9.** Dalgacık Transformasyonunun şematik görüntüsü.

Değişik ölçeklerdeki ve değişik yönlerdeki şematik görüntülerde kemik yumuşak doku geçiş kesiminde daha yüksek frekans nedeniyle daha belirgin konturlar seçilmekte.

#### 2.1.1.5. Özellik seçimi ve azaltımı

Tekstür analizi ile çok sayıda özellik çıkarma yönteminin oluşu ve her yöntemin kendi içinde çok daha ayrıntılı alt gruplarının oluşu ve bu özelliklerin

kombinasyonlar halinde kullanılabilmesi bize çok sayıda değerlendirmesi güç bir veri yığını oluşturur. Gereksiz veya ilgisiz özellikler sınıflandırma performansını engeller ve boyutsallık sorunlarına yol açarak daha kompleks, uygulaması güç analiz modellerine neden olur. Bu nedenlerle özellik azaltımı ve seçimi işlemlerine gerek duyulur. Özellik seçimi ile kullanılacak analiz özelliklerinden yapılacak işlem için en ilgili olanları seçilebilir (2).

Temel bileşen analizi “principal component analysis” (PCA) veya lineer diskriminant analizi “linear discriminant analysis” (LDA) gibi yöntemler özellik azaltmada kullanılırken yine de tüm orijinal özelliklerin hesaplanmasını gerektirdiğinden özellik seçim yöntemleri olarak kabul edilmezler

**a. Filtre özellik seçme yöntemleri:** Kapsamlı bir arama ile tüm olası özellikler ve kombinasyonlar bir sınıflandırıcıya girdi olarak verilerek test edilebilir ve en iyi ayrımı sağlayan özellikler seçilebilir. Ancak bu işlem uzun ve yorucu bir işlemdir. Filtre yöntemler ile belirli bir özellik test edilerek ayırıcı gücü yüksek özellik bulunabilir. Tipik istatistiksel yöntemler kullanılarak istatistiksel öneme sahip özellikler seçilebilir (2). Fisher katsayısı “Fisher Coefficient” gruplar arası varyansların grup-içi varyanslara oranını tanımlar. Sınıflama Hatası Olasılığı “probability of classification error” (POE) ve ortalama korelasyon katsayısı “average correlation coefficient” (ACC) verilerine dayanan farklı bir filtre özellik seçimi metodu da kullanılabilir.

Bu tariflediğimiz filtre yöntemleri MaZda yazılımıyla doğrudan kullanacağımız verilere uygulanabilmektedir.

**b. Sarmalayıcı yöntemler:** Filtre yöntemleri eğitim datasını kullanarak diğer verileri filtrelemeye çalışır. Bu sebeple belirli bir alt grup özelliğinin öngörücü özelliğini dikkate almaz. Sarmalayıcı yöntemler bir sınıflama algoritmasından faydalanır ve optimum sınıflandırma performansı saptayan özelliklerin alt gruplarını araştırır. Özyinelemeli özellik ortadan kaldırılması (recursive feature elimination), bir sınıflandırıcıyı tekrar tekrar eğiterek en küçük sıralama puanına sahip özelliği kaldırır. Sonuçta en iyi sınıflandırmayı sağlayan özellikler alt kümesini seçer.

### **2.1.1.6. Sınıflama**

Sınıflama işlemi ile veriler sayesinde ileriye yönelik doku segmentasyonu olarak bilinen yöntemle otomatik tanı koyma sistemleri için kullanılabilir (2).

İki ya da daha fazla grup arasında farklılık olup olmadığını göstermek için basit istatistiksel testler kullanılabilir. Ancak özellik seçimi bölümünde bahsettiğimiz gibi seçtiğimiz farklı özelliklerin birlikte değerlendirilebilmesi için daha kompleks algoritmalara ihtiyaç duyulmaktadır.

Abartılmış değerlerden kaçınmak için her zaman verileri eğitim ve doğrulama kümelerine ayrılması önerilir; böylece yeni verilerle ilgili sonuçlar bildirilebilir. Seyrek verilerde sonuçları ROC analizi ile ifade etmek önerilmektedir.

### **2.1.2. Tekstür Analiz Yazılımları**

Bu çalışmada analizler için MaZda programını (versiyon 4.6, <http://www.eletel.p.lodz.pl/mazda/>) kullanılmıştır (33). Bu program ile istatistiksel, yapısal, model temelli ve dönüşüm temelli yöntemlere örnekler bulunması, kendi içerisinde ROI çizilebilmesi, " $\mu \pm 3\sigma$ " algoritması ile normalizasyon yapılabilmesi, görüntü piksel indirgeme işlemlerinin yapılabilmesi, kendi içerisinde özellik seçim için ayrı yöntemler bulunması önemli avantajlarıdır. Ayrıca program paketi içerisinde gelen B11 yazılımı ile seçilen 30 kadar özellik için diskriminant analizleri, kümeleme ve sınıflama algoritmaları çalıştırılmaktadır.

Literatürde TexRAD (<https://fbkmed.com/textrad-landing-2/>), LIFEx (<https://www.lifexsoft.org/>) gibi çeşitli tekstür analiz programları, IBEX([http://bit.ly/IBEXSrc\\_MDAnderson](http://bit.ly/IBEXSrc_MDAnderson)) gibi matlab temelli tekstür analiz programları da mevcuttur (41–43).

## 2.2. RENAL KİTLELER

Renal hücreli kanser (RHK) dünya genelinde en sık kanserler arasında erkeklerde 6'ncı, kadınlarda 10'uncu sırada yer almaktadır (44). RHK tanısı son yıllarda giderek artmaktadır. Artışın en önemli sebebi diğer sebeplerle yapılan görüntülemelerde saptanan lezyonlar olarak belirtilmektedir (45). Ne yazık ki tanı oranlarındaki artış klinik sonuçları iyileştirmemiştir. Yapılan bir çalışma RHK ile ilişkili mortalitenin belli bir zaman aralığında 100 000 kişide 1.5'tan 6.5'a yükseldiğini göstermektedir (45,46). Öte yandan insidental olarak saptanan tümörlerin büyük bir kesimi daha küçük boyutlu, daha yavaş büyüyen tümörlerden oluşmaktadır (45,47). Dahası bu lezyonlarının görüntüleme özelliklerinin benign lezyonlardan ayırt edilememesi sebebiyle bir çok olgu gereksiz opere olmaktadır.

Bu sebeplerle görüntüleme yöntemleri ile renal kitlelerin en azından benign malign ayrımını yapabilecek şekilde karakterizasyonu, RHK alt tiplendirmesinin yapılabilmesi, tümörün agresifliğinin gösterilebilmesi çok daha önemli bir noktaya gelmektedir.

Renal kitleye yaklaşımda ilk basamak benign kistlerden ayrımını yapmaktır. Bu ayırım için BT inceleme ile ölçülebilen Hounsfield Units (HU) değerleri oldukça yarar sağlamaktadır. 20HU'nun altındaki homojen kitleler ve 70HU'nun üzerindeki homojen kitleler sırasıyla basit kist ve hemorajik/proteinöz kistlerce oluşmaktadır (47).

2016 Yılında WHO böbrek kitlelerini patolojik, epidemiyolojik ve genetik özellikleri göz önünde bulundurarak revize etmiştir (48). Bu sınıflama Tablo 4'te özetlenmiştir. Tabloda tarif edilen lezyonların büyük kesimi sporadik ve nadir görülen lezyonlardır. Bu lezyonlardan sık karşılaşılanları sırasıyla malign ve benign lezyonlar olmak üzere ele alınacaktır.

**Tablo 4. WHO 2016 Sınıflamasına göre böbrek tümörlerinin gösterimi.**

<b>Renal hücreli tümörler</b>		
<ul style="list-style-type: none"><li>• Berrak hücreli renal hücreli karsinom</li><li>• Düşük malignite potansiyelli multilokuler kistik neoplazm</li><li>• Papiller renal hücreli karsinom</li><li>• Herediter leiomyomatozis ve renal hücreli karsinom sendromu ile ilişkili renal hücreli karsinom</li><li>• Kromofob renal hücreli karsinom</li><li>• Toplayıcı kanal karsinom</li><li>• Renal meduller karsinom</li><li>• MiT ailesel translokasyonlu renal hücreli karsinom</li><li>• Süksinat dehidrogenaz eksikliğine bağlı renal hücreli karsinom</li><li>• Müsinöz tübüler ve işsi hücreli karsinom</li><li>• Tubulokistik renal hücreli karsinom</li><li>• Edinsel kistik hastalık ilişkili renal hücreli karsinom</li><li>• Berrak hücreli papiller renal hücreli karsinom</li><li>• Renal hücreli karsinom, sınıflandırılmayan</li><li>• Papiller adenom</li><li>• Onkositom</li></ul>		
<b>Metanefrik tümörler</b>		
<ul style="list-style-type: none"><li>• Metanefrik adenom</li><li>• Metanefrik adenofibrom</li><li>• Metanefrik stromal tümör</li><li>• Çocukluk çağı nefroblastik ve kistik tümörleri</li><li>• Nefrojenik kalıntılar</li><li>• Nefroblastom</li><li>• Kistik parsiyel diferansiye nefroblastom</li><li>• Pediyatrik kistik nefroma</li></ul>		
<b>Mezenkimal tümörler</b>		
<table border="0"><tr><td><ul style="list-style-type: none"><li>• <b><u>Eriskinlik çağı mezenkimal tümörler</u></b></li><li>• Leiomyosarkom</li><li>• Anjiosarkom</li><li>• Rabdomyosarkom</li><li>• Osteosarkom</li><li>• Sinovyal sarkom</li><li>• Ewing Sarkom</li><li>• Angiomyolipom</li><li>• Epiteloid anjiomyolipom</li><li>• Leiomyom</li><li>• Hemanjiom</li><li>• Lenfanjiom</li><li>• Hemanjioblastom</li><li>• Jukstaglomerüler hücreli tümör</li><li>• Renomedüller intersitisyel hücreli tümör</li><li>• Schwannom</li><li>• Soliter fibröz tümör</li></ul></td><td><ul style="list-style-type: none"><li>• <b><u>Çocukluk çağı mezenkimal tümörleri</u></b></li><li>• Berrak hücreli sarkom</li><li>• Rabdoid tümör</li><li>• Konjenital mezoblastik nefroma</li><li>• İnfantın ossifiye renal tümörü</li></ul></td></tr></table>	<ul style="list-style-type: none"><li>• <b><u>Eriskinlik çağı mezenkimal tümörler</u></b></li><li>• Leiomyosarkom</li><li>• Anjiosarkom</li><li>• Rabdomyosarkom</li><li>• Osteosarkom</li><li>• Sinovyal sarkom</li><li>• Ewing Sarkom</li><li>• Angiomyolipom</li><li>• Epiteloid anjiomyolipom</li><li>• Leiomyom</li><li>• Hemanjiom</li><li>• Lenfanjiom</li><li>• Hemanjioblastom</li><li>• Jukstaglomerüler hücreli tümör</li><li>• Renomedüller intersitisyel hücreli tümör</li><li>• Schwannom</li><li>• Soliter fibröz tümör</li></ul>	<ul style="list-style-type: none"><li>• <b><u>Çocukluk çağı mezenkimal tümörleri</u></b></li><li>• Berrak hücreli sarkom</li><li>• Rabdoid tümör</li><li>• Konjenital mezoblastik nefroma</li><li>• İnfantın ossifiye renal tümörü</li></ul>
<ul style="list-style-type: none"><li>• <b><u>Eriskinlik çağı mezenkimal tümörler</u></b></li><li>• Leiomyosarkom</li><li>• Anjiosarkom</li><li>• Rabdomyosarkom</li><li>• Osteosarkom</li><li>• Sinovyal sarkom</li><li>• Ewing Sarkom</li><li>• Angiomyolipom</li><li>• Epiteloid anjiomyolipom</li><li>• Leiomyom</li><li>• Hemanjiom</li><li>• Lenfanjiom</li><li>• Hemanjioblastom</li><li>• Jukstaglomerüler hücreli tümör</li><li>• Renomedüller intersitisyel hücreli tümör</li><li>• Schwannom</li><li>• Soliter fibröz tümör</li></ul>	<ul style="list-style-type: none"><li>• <b><u>Çocukluk çağı mezenkimal tümörleri</u></b></li><li>• Berrak hücreli sarkom</li><li>• Rabdoid tümör</li><li>• Konjenital mezoblastik nefroma</li><li>• İnfantın ossifiye renal tümörü</li></ul>	
<b>Mikst epitelyal ve stromal tümör ailesi</b>		
<ul style="list-style-type: none"><li>• Kistik nefroma</li><li>• Mikst epitelyal ve stromal tümör</li></ul>		
<b>Nöroendokrin tümör</b>		
<ul style="list-style-type: none"><li>• İyi diferansiye nöroendokrin tümör</li><li>• Büyük hücreli nöroendokrin karsinom</li><li>• Küçük hücreli nöroendokrin karsinom</li><li>• Feokromasitoma</li></ul>		
<b>Diğer tümörler</b>		
<ul style="list-style-type: none"><li>• Renal hematopoetik neoplazmlar</li><li>• Germ hücreli tümörler</li></ul>		
<b>Metastatik tümörler</b>		

## 2.2.1. Malign Renal Lezyonlar

### 2.2.1.1. Renal Hücreli Kanser (RHK)

RHK en sık karşılaşılan böbrek malign epitelyal tümörüdür. Tüm solid malign renal kitlelerin yaklaşık %90'ını oluşturmaktadır (6). RHK alt tiplerinin WHO'ya göre sınıflandırılmasının 2016 revizyonu Tablo 5'te belirtilmiştir (47,48).

**Tablo 5.** WHO 2016 Sınıflamasına göre RHK alt-tipleri ve genel özellikleri gösterilmektedir.

RHK alt-tipi	Sıklık (Tüm RHK'lere göre %)	Hasta Yaşı (genel)	İlişkili olduğu hastalıklar ve predispozan faktörler
Berrak Hücreli	%65-75	>50 yaş	Von Hippel-Lindau sendromu Tüberöz Skleroz
Papiller	%15-20	>50 yaş	Hereditör Papiller RHK
Kromofob	%5	>50 yaş	Birt-Hogg-Dube Sendromu (Onkositomlar ile birlikte)
Düşük malignite potansiyelli Multiloküler kistik noplazi	<1	Orta yaşlı erişkinler	
Toplayıcı Sistem Karsinomu	1-2	>50 yaş	
Hereditör Leyomyomatosiss ve RHK	Nadir	36-39 yaş	Kutanöz leiomyomlar, Uterin leiomyomlar
Renal medüller karsinom	Nadir	20-30'lu yaşlar	Orak hücreli anemi
Mit Ailesel Translokasyon RHK	Pediyatrik RHK'lerin %40'ı, erişkin RHK'lerin %1.6-4'ü	Çocukluk ve genç erişkinlik	
Suksinat dehidrogenaz eksikliği ilişkili RHK	Nadir	38 yaş	
Müsinöz tübüler ve işsi hücreli karsinom	<%1	58 yaş	
Tübülökistik RHK	<%1	58 yaş	
Kazanılmış kistik hastalık ilişkili RHK	Son dönem böbrek hastalarında izlenen epitelyal neoplazilerin %36'sı		%50 multifokal
Berrak hücreli papiller RHK	Tüm renal tümörlerin %1-4'ü	60 yaş	Son dönem böbrek hastalarında ve sporadik olarak
RHK, sınıflanmamış	<%5	Değişken	

**a. Berrak hücreli RHK:** En sık karşılaşılan RHK alt-tipidir. Tüm RHK'lerin %65-75'ini oluşturur. Yaklaşık %95'i sporadiktir. Geri kalanları başta von Hippel-Lindau ve tüberoz skleroz olmak üzere herediter sendromlar ile ilişkilidir (6). Klinik seyri en kötü olan RHK alt-tipidir. 5 yıllık sağ kalım %44-69 civarındadır (6,49). Nadiren sarkomatoid veya rabdoid dejenerasyon gösterebilir ve bu durum prognozu olumsuz yönde etkilemektedir (6).

Renal kortekste proksimal tübül epitelinden gelişir. Makroskobik olarak yoğun yağ içeriğine bağlı sarımtırak bir renkte görünür. Histolojik olarak, kolesterol birikimi ve çözülmüş lipidlerin oluşturduğu saydam olarak görülen hücre sitoplazmasına sahip hücrelerden oluşur (6,50). Eozinofilik granüler sitoplazmalar da barındırabilir. Nekroz, hemoraji, kistik dejenerasyon alanları içerebilir (50). Histolojik evreleme için en sık Fuhrman sınıflama sistemi kullanılır. Bu sınıflama çekirdek boyutu ve özelliklerini temel alan bir sınıflamadır. Bu sınıflamada berrak hücreli tümörler dört derecede (I-IV) sınıflandırılmıştır. Evre I-II düşük dereceli, evre III-IV yüksek dereceli olarak kabul edilmektedir (6).

Manyetik rezonans incelemede; T1 ağırlıklı görüntülerde böbrek parankimine kıyasla izointens veya hafif hipointens görülebilir. T2 ağırlıklı görüntülerde tipik olarak yüksek intensitede izlenirler. Hemoraji, nekroz gibi komponentleri nedeniyle heterojen yapıda görülürler. Hipervasküler tümörler olduklarından yoğun kontrastlanma gösterirler. Arteriyel faz kontrastlanmaları diğer RHK alt tiplerinden daha belirgin olarak izlenir (45,50). İntrasellüler lipid komponentine bağlı olarak dış faz görüntülerde sinyal kaybı gösterirler (50). Ancak bu bulgu yağdan fakir anjiomyolipomlarda da izlenebildiğinden nonspesifik olarak kabul edilmelidir. Faz içi görüntüye göre %25'ten fazla sinyal kaybının bulunması mikroskobik yağ varlığı için bir gösterge kabul edilir (6,50). Ayrıca kortikomedüller faz görüntülerde BT'de hipodens, T1 ağırlıklı ve T2 ağırlıklı görüntülerde hipointens psödokapsül görünümü izlenebilir. Bu görünümün bütünlüğünün bozulması yüksek evre için bir uyarıcı olmalıdır. Komşu vasküler yapılara sık invazyon riski nedeniyle komşu vasküler yapılar iyi değerlendirilmelidir. Berrak hücreli tümörler difüzyon kısıtlarlar ve düşük ADC değerlerinin Fuhrman evresi ile korelasyon gösterdiği gösterilmiştir (6). Kistik berrak hücreli RHK'ler daha çok irregüler duvar ve kalınlaşmış septanın eşlik ettiği, kistik içeriği homojen olarak izlenen lezyonlar şeklinde görülür (6).

**b. Papiller RHK:** İkinci sıklıkta izlenen RHK alt-tipi olup tüm RHK'lerin yaklaşık %15-20'sini oluşturmaktadır. %4 olguda bilateral, %23 oranında multifokaldirler (6). Prognozu berrak hücreli karsinoma göre daha iyidir. 5 Yıllık sağ kalım %90'ın üzerindedir (6,50).

Makroskopik olarak hemoraji, nekroz alanları içerebilir. Histolojik olarak iğ şeklinde sıralanmış hücreler ile nekroz, hemoraji alanları bulunmaktadır. Bazofilik (tip I) ve Eozinofilik (tip II) tipleri mevcuttur. Tip II daha yüksek patolojik evre ve daha kötü prognoz ile seyredir (6,50).

Manyetik rezonans incelemede genellikle düzgün sınırlı homojen lezyon olarak izlenir. Genelde T1 ağırlıklı ve T2 ağırlıklı görüntülerde hipointens olarak izlenen fibröz bir kapsül bulunur. T2 ağırlıklı serilerde hipointens olarak izlenir. Daha hipovasküler tümörlerdir. Giderek artan kontrastlanmaları izlenir. Hemosiderin içerip in-faz görüntülerde hipointens alanlar barındırabilir. Kistik papiller RHK'ler papiller çıkıntılar, mural nodül barındırabilir (6). Papiller RHK'ler nadiren mikroskopik yağ içerir. Difüzyon ağırlıklı görüntülemeye belirgin düşük ADC değerlerine sahiptirler (6).

**c. Kromofob RHK:** 3'üncü Sıklıkta izlenen RHK tipidir. Tüm RHK'lerin yaklaşık %5'ini oluşturur. Diğer alt tiplerden daha iyi prognoza sahiptir (6,50).

Makroskopik olarak solid, konturları hafif ondülasyon gösteren düzgün sınırlı koyu renkli tümörler şeklinde görülürler. Diğer RHK alt tiplerinden daha büyük olma eğilimindedirler. Histopatolojik olarak, bu tümörlerin renal korteksin interkale hücrelerinden köken almakta ve vasküler septalar boyunca solid tabaka benzeri yapıda saydam veya eozinofilik sitoplazmaya sahip hücrelerden oluşmaktadır (6).

Manyetik rezonans incelemede, iyi sınırlı ve homojen olarak izlenirler. T2 sinyalleri düşük ya da ara intensitede olabilir. Kistik nekrotik değişiklikler büyük tümörlerde bile nadiren izlenir. Kontrastlanma paternleri aradadır. Berrak hücrelilerden az, papillerlerden çok kontrastlanırlar. Santral skarları ve bu alanda tekerlek benzeri (spoke -wheel) kontrastlanma izlenebilir. Ancak bu kontrastlanma tipi onkositomlarda da görülebilir. Hipovasküler ve hipervasküler özellikteki farklı



alanların bir arada bulunmasıyla oluşan segmental kontrastlanma inversiyonları olarak tariflenen bulgu izlenebilir. Bu görünüm diğer alanlar hipovasküler yapıdayken kontrast sonrası erken alınan görüntülerde belirgin kontrastlanan, geç faz görüntülerde daha hipointens görünüm alan kesimler şeklinde izlenir. Kalsifikasyon kromofob RHK'nin sık görülen bir bulgusudur. Papiller RHK'ye benzer şekilde difüzyon kısıtlıdır (6,50).

#### **2.2.1.2. Renal lenfoma**

Lenfomanın böbrek tutulumu genelde non-Hodgkin lenfomaya sekonder olarak izlenir. Bu olguların otopsi serilerinde %50'lere varan böbrek tutulumları izlenmektedir. Renal lenfoma, mutlipl kitleler, RHK'ye benzer görünümde tek kitle veya infiltratif renal hastalık şeklinde görülebilir (45).

Görüntülemelerde BT ve MR incelemelerinde homojen olarak izlenirler. Kontrast madde enjeksiyonu sonrası renal parankime kıyasla daha az kontrastlanma gösterirler (45).

#### **2.2.1.3. Metastaz**

Renal metastazlar genellikle böbreğin kortikomedüller bileşkesi düzeyinde izlenirler. Hastalarda genellikle bilinen bir malignite mevcuttur. Öyküsü olmayan bir olguda RHK'lerden ayırım zordur (45).

### **2.2.2. Benign Renal Lezyonlar**

#### **2.2.2.1. Anjiomiyolipom (AML)**

AML dismorfik vasküler yapılar, düz kaslar ve matür yağ dokusu içeren benign böbrek kitleleridir. Kadınlarda 2 kat daha fazla görülürler. Tübero skleroz olgularının %55-90'ında, lenfanjiomiyomatozis olgularının %30-50'sinde

görülürler. Büyük AML'lerde spontan kanama olması Wunderlich Sendromu olarak bilinir ve hayatı tehdit eden ciddi bir komplikasyondur (45).

Anjiomiyolipom tanısı makroskobik yağ görüldüğünde kolaydır. Klasik AML'ler yağ içeriğine bağlı T1 ağırlıklı görüntülerde hiperintens olarak izlenirler. Yağ baskılı serilerde sinyalleri baskılanırlar. Dış faz görüntülerde çini mürekkebi artefaktına neden olurlar. Literatürde makroskobik yağ içeren RHK olguları da tanımlanmıştır. Ancak bunlarda lezyonda kalsifikasyon da genellikle izlenmektedir. Bazen de RHK'lerin perinefrik yağı veya renal sinüsteki yağı sarması makroskobik yağ içeriyormuş izlenimi verebilir (6).

Makroskobik yağ içermeyen yağdan fakir AML'leri RHK'den ayırmak güçtür. Yağdan fakir AML'ler tüm AML'lerin yaklaşık %5'ini oluşturmaktadır. Histopatolojik olarak geniş bir örneklem alanın %25'inden az yağ hücresi içeren AML'ler yağdan fakir AML olarak tanımlanmaktadır. Yağdan fakir AML'ler büyük oranda düz kas hücresi ve bir miktar vasküler yapı barındırır. MR görüntülemeye homojen düşük T2 sinyali sergilerler. Yağdan fakir AML'ler erken yoğun kontrastlanma ve kısmi yıkanma gösterirler. Ekzofitik olabilirler. Yağ baskılama sekanslarında amaç makroskobik yağı göstermektir. Yağdan fakir AML'lerdeki mikroskobik yağı göstermek için faz içi, dış faz görüntüler kullanılabilir. Ancak RHK'lerde mikroskobik yağ içerebileceğinden mikroskobik yağ varlığı spesifik değildir. Konvansiyonel MR sekansları bu durumda ek yarar sağlayabilir. Mikroskobik yağ en sık berrak hücreli alt-tipinde izlenir. T2 ağırlıklı serilerde berrak hücreli RHK'nin hiperintens olarak izlenmesi, yağdan fakir AML'nin ise hipointens olarak izlenmesi beklenmektedir (6,45,50). AML'ler de difüzyon kısıtlaması gösterirler.

#### **2.2.2.2. Onkositom**

Renal kitlelerin yaklaşık %3-7'sini oluştururlar. 7'nci dekatta pik yaparlar. Erkeklerde daha sık olarak izlenirler. Onkositomlar kromofob RHK'ler ile aynı orijinden gelişirler. Bu nedenle bazı ortak histopatolojik ve görüntüleme bulguları

mevcuttur. Kromofob RHK ve onkositomlar onkositik neoplaziler olarak isimlendirilirler.

Makroskopik olarak koyu görünümde, oldukça homojen ve genelde kapsüllü görünümde izlenirler. Histopatolojik olarak eozinofilik sitoplazmadan zengin geniş poligonal hücrelerden oluşurlar. Fibröz ya da hiyalin bağ dokusu yapısında santral skarları bulunabilir.

Görüntüleme bulguları RHK ile ayırıcı tanısında çoğunlukla fayda sağlamamaktadır. T2 ağırlıklı görüntülerde genelde hiperintens, T1 ağırlıklı görüntülerde genelde hipointens olarak izlenirler. RHK'lerde görülebileceği gibi olguların hemen hemen yarısında düşük sinyalli bir kapsül izlenmektedir. Olguların hemen hemen yarısında kromofob RHK'lerde olduğu gibi santral skar izlenmektedir. Yine kromofob RHK'lerde olduğu gibi segmental kontrastlanma inversiyonları izlenebilir. Difüzyon inceleme de ayırıcı tanısında ek bilgi sağlamamaktadır. Bazı çalışmalar ADC değerlerinin RHK'lere kıyasla daha yüksek olduğunu, bazı çalışmalar da benzer olduğunu göstermektedir (6,51).

### **2.2.2.3. İnflamatuvar Durumlar ve Psödotümörler**

Bazen neoplastik olmayan durumlar kitle izlenimi verebilir. Hipertrofik Bertini Kolonu bu durumlardan en sık karşılaşılandır. Normal parankim özellikleri ve parankime benzer kanlanma göstermesi ile sonografik incelemede kolaylıkla ayırt edilebilir. Bazı inflamatuvar ve granüloamatöz hastalıklar da kitle görünümüne neden olabilir. Bu durumda hastanın klinik öyküsü ve fizik muayene bulgularının bilinmesi doğru tanıyı koymada önem taşımaktadır (45,52).

### **3. GEREÇ VE YÖNTEM**

Bu çalışmada radyolojik görüntüleme yapı çözümü uygulamaları kullanılarak tekstür analizi bulgularının (i) RHK ve onkositom ayrımındaki yerini, (ii) RHK alt tiplendirmesine olan katkısını, (iii) Berrak hücreli RHK'nin nükleer grade'i ile ilişkisini değerlendirmeyi amaçlandı.

#### **3.1. OLGULAR**

Hastane PACS (Picture Archiving and Communication System) sisteminde Kasım 2016 – Kasım 2018 tarihleri arasında üst abdomen MR incelemesi yapılan olgular taranarak seçildi. Çalışmaya, (a) Cerrahi işlem öncesi MR görüntüleri elde olunmuş olan; (b) MR sonrasında cerrahi ile patolojik tanısı konmuş; (c) daha önce geçirilmiş radyoterapi ya da kemoterapi öyküsü olmayan olgular dahil edildi. Çalışmanın retrospektif doğası nedeniyle incelenen lezyon alanında hareket kaynaklı başta olmak üzere artefakt bulunan ilgili sekanslar çalışma dışında bırakıldı.

#### **3.2. GÖRÜNTÜLEME**

MR incelemelerine ait görüntüler üç ayrı MR cihazından; 3T (Achieva; Philips Medical Systems, Best, Hollanda), 1.5T (Gyrosan Intera; Philips Medical Systems, Best, Hollanda) ve 1.5T (Magnetom Symphony, Siemens AG, Erlangen, Almanya) MR cihazlarından elde olunmuştu.

Sekansların genel özellikleri korunmakla birlikte seçilen parametreler bağlamında cihazlar arasında farklılıklar mevcuttu. Her sekansa ait görüntüler kendi içlerinde değerlendirildi.

Radyolojik görüntüleme yapı çözümü uygulamaları kullanılarak tekstür analizine ait değerlendirmeler;

Aksiyel kontrast sonrası 30.sn. ve 70.sn. yağ baskılı gradient T1 ağırlıklı (TE: 1,43-4,76ms, TR: 3,02-4,37ms),

Aksiyel gradient T2 ağırlıklı (TE: 1,15-1,82ms, TR: 3,26-3.65ms),

Aksiyel T2 SPAIR (TE: 70-80ms, TR: 440-1278ms),

Aksiyel dış faz “out of phase” (TE: 1,15-2,4ms, TR: 116-219ms),

Aksiyel ADC “Apparent diffusion coefficient” (TE: 51-78ms, TR: 1244-2800ms, b değeri 800sn./mm<sup>2</sup>,) görüntülerine uygulandı.

Her sekasta alınan görüntüler ayrı ayrı incelendi. Artefaktlı olanlar inceleme dışında bırakıldı. Tüm cihazlarda ve tüm sekanslarda görüntü matrisi 256x256 piksel ile oluşturulmuştu. Görüntüler tekstür özelliklerini belirginleştirmek için görüntüleme programı yardımı içine gömülü standart interpolasyon algoritması ile 500x500 piksele genişletildi ve BMP (bitmap image) formatında kaydedildi.

### **3.3. TEKSTÜR ANALİZİ**

İncelemenin bu aşamadan sonraki tekstür analizi ön hazırlığı ve özellik çıkartma ve özellik seçme işlemleri popüler tekstür analiz uygulaması MaZda (versiyon 4.6, <http://www.eletel.p.lodz.pl/mazda/>) kullanılarak yapıldı (33).

#### **3.3.1. ROI (region of interest) Çizimi**

Tüm imajlardaki lezyonlara öncelikle manuel olarak lezyon sınırlarının dışına taşmayacak şekilde 2B ROI'ler çizildi. Lezyon sınırlarında özellikle gradiyenti ağırlıklı görüntülerde yağ-sıvı ara yüzlerinde gelişebilecek artefaktların dışarıda bırakılmasına özen gösterildi.

### 3.3.2. ROİ Ön Hazırlığı

Görüntüler arasındaki farklı cihaz ve farklı protokollere bağlı olası farklılıkların ortadan kaldırılması için imaj grilik değerleri “ $\mu \pm 3\sigma$ ” normalizasyon metodu kullanılarak normalize edildi. Normalizasyon sonrası tüm imajlar tekstür özelliklerini belirginleştirmek için tüm analiz metotları için 8bit/piksele indirildi. Ayrıca tekstür özelliklerine etkisini görmek için T2 ağırlıklı görüntülerdeki veriler hem 8bit/piksele, hem 6bit/piksele indirilerek ayrı ayrı değerlendirildi.

### 3.3.3. Tekstür Özelliklerinin çıkarımı

ROİ çizilen ve normalizasyon basamakları tamamlanan imajlarda histogram, gradient, run-length matrix, co-occurrence matrix, otomatik regresyon modeli ve dalgacık transformasyonu analiz yöntemlerine ait 300’den fazla farklı parametre değerlendirildi.

### 3.3.4. Tekstür Özelliklerinin seçimi

Belirtilen sekanslarda çalışılan 300’den fazla özellikten ayırıcı tamda en fazla yararı olan 10 tanesi Fisher Katsayısı yöntemi ve POE+ACC yöntemleri kullanılarak seçildi.

## 3.5. İSTATİSTİKSEL ANALİZ

Fisher katsayısı veya POE+ACC yöntemiyle özellik azaltma ve seçme basamağı tamamlanan veriler lineer ilişkileri dışlamak için Pearson korelasyon testi ile değerlendirildi. Pearson korelasyon testi ile lineer veya lineere yakın ilişkisi olan gruplar değerlendirilerek ikinci bir özellik azaltma basamağı uygulandı. Sonrasında her bir sekans için seçilen özelliklere yönelik Kanonik diskriminant analiz ile fonksiyonlar belirlendi. Her bir fonksiyondaki değişkenler için katsayılar elde

edilerek fonksiyonlara ait formüller oluşturuldu ve grup merkezleri oluşturuldu. Ayırt edici gücü en yüksek iki fonksiyonda verilerin dağılımı grafik olarak gösterildi. Ayırt edici gücü en yüksek olan fonksiyonlar için doğru sınıflama başarıları analiz edildi.



## 4. BULGULAR

Toplamda 32 (24 Erkek, 8 Kadın) hastaya ait MR görüntüleri retrospektif olarak değerlendirildi. Görüntüleme anında hasta yaşları 32 ile 88 arasında değişmekteydi. Ortalama hasta yaşı 60'tı.

Olguların 21'inin(%66) berrak hücreli RHK, 5'inin (%16) papiller RHK, 3'ünün (%9) kromofob RHK, 3'ünün (%9) Onkositom patolojik tanıları mevcuttu.

3T (Achieva; Philips Medical Systems, Best, Hollanda), 1.5T (Gyrosan Intera; Philips Medical Systems, Best, Hollanda) ve 1.5T Siemens (Magnetom Symphony, Siemens AG, Erlangen, Almanya) MR cihazlarından sırasıyla 12, 17 ve 3 hastadan görüntüler değerlendirildi.

Artefaksız olan görüntülerden;

Kontrast sonrası 30. Sn. T1 ağırlıklı görüntüler için 20 hasta (12 berrak hücreli RHK, 3 papiller RHK, 3 kromofob RHK, 2 onkositom),

Kontrast sonrası 70. Sn. T1 ağırlıklı görüntüler için 21 hasta (12 berrak hücreli RHK, 4 papiller RHK, 2 kromofob RHK, 3 onkositom),

T2 ağırlıklı görüntüler için 26 hasta (17 berrak hücreli RHK, 4 papiller RHK, 2 kromofob RHK, 3 onkositom),

T2 SPAIR görüntüler için 28 hasta (19 berrak hücreli RHK, 3 papiller RHK, 3 kromofob RHK, 3 onkositom),

Dış faz (out of phase) görüntüler için 30 hasta (20 berrak hücreli RHK, 4 papiller RHK, 3 kromofob RHK, 3 onkositom),

ADC görüntüler için 29 hasta (19 berrak hücreli RHK, 5 papiller RHK, 2 kromofob RHK, 3 onkositom) için değerlendirildi.

MaZda programı ile görüntüler tekstür özellikleri açısından analiz edildikten sonra en ayırt edici 10 özellik Fisher Katsayısı kullanılarak seçildi. Seçilen özellikler Tablo 6'da özetlenmiştir. Bu özellikler Tablo 6'da belirtildiği şekliyle daha sonra farklı sekanslar için ayrı ayrı incelendi.



**Tablo 6.** Çalışılan tüm sekanslar için ayırt edici özellikler ve diskriminant analizi sonucunda orijinal gruplara göre doğru sınıflanan olguların oranları gösterilmiştir.

Sekans	Seçilen yöntem Doğru Sınıflanan Veri	Sekans	Seçilen yöntem Doğru Sınıflanan Veri
<b>Kontrast sonrası 30.sn. T1</b>	<b>Fisher katsayısı 19/20 %95</b> S(0,5)DifEntrp S(0,4)DifEntrp S(3,3)DifEntrp S(4,0)DifEntrp S(3,0)DifEntrp S(4,-4)DifEntrp S(4,4)DifEntrp S(0,3)DifEntrp S(5,0)DifEntrp WavEnLL_s-1	<b>Kontrast sonrası 70.sn. T1</b>	<b>Fisher katsayısı 30/30 %100</b> WavEnLL_s-3 Variance S(0,1)DifEntrp 45dgr_LngREmph S(3,-3)DifEntrp WavEnHH_s-2 S(2,0)SumOfSqS S(4,-4)DifEntrp WavEnLH_s-4 Vertl_ShrtREmp
<b>T2 SPAIR</b>	<b>Fisher katsayısı 25/28 %89,3</b> WavEnLL_s-4 WavEnLL_s-3 WavEnHH_s-1 S(5,0)InvDfMom WavEnHH_s-2 S(0,5)DifVarnC S(0,4)DifVarnC S(3,-3)DifVarnC S(1,1)Contrast S(0,3)DifVarnC	<b>T2 6bit/piksel</b>	<b>POE+ACC 25/26 %96,2</b> S(4,4)DifEntrp GrSkewness S(2,2)Entropy S(5,5)SumOfSqS WavEnHL_s4 S(0,4)Entropy S(0,3)Entropy Skewness S(2,0)Entropy Teta2
<b>T2 8bit/piksel</b>	<b>Fisher katsayısı 25/26 %100</b> S(3,3)InvDfMom S(5,0)SumOfSqS WavEnLH_s-4 WavEnLL_s-3 S(2,-2)SumOfSqS S(2,0)InvDfMom Teta2 S(4,0)SumOfSqS S(3,-3)SumOfSqS S(4,-4)InvDfMom	<b>T2 8bit/piksel</b>	<b>POE+ACC 25/26 %96,2</b> WavEnHH_s-4 WavEnHL_s-4 S(3,3)InvDfMom S(5,-5)SumOfSqS S(5,5)Entropy S(0,4)Entropy S(3,0)Entropy S(5,5)AngScMom S(5,-5)AngScMom GrSkewness
<b>Dış Faz</b>	<b>Fisher katsayısı 28/30 %93,3</b> S(2,0)InvDfMom S(1,0)InvDfMom S(3,0)InvDfMom S(5,0)InvDfMom Teta4 S(4,0)InvDfMom Horzl_LngREmph S(0,5)InvDfMom Horzl_Fraction WavEnLL_s-3	<b>ADC</b>	<b>Fisher katsayısı 23/29 %75,9</b> S(0,2)DifVarnC WavEnHL_s-3 S(5,5)SumEntrp Variance S(5,-5)AngScMom S(4,0)SumVarnC S(4,-4)AngScMom WavEnLL_s-1 S(5,5)Correlat WavEnLH_s-3

## 4.1. RHK – ONKOSİTOM VE RHK ALT TİPLERİNİN AYRIMINA YÖNELİK ANALİZLER

### 4.1.1. Kontrast Sonrası 30.sn. T1 Ağırlıklı Kesitlerinin Analizi

Kontrast sonrası 30.sn. T1 ağırlıklı kesitler için çalışılan özelliklerden Fisher katsayısı kullanılarak seçilen özellikler için kanonik diskriminant fonksiyonu uygulanmıştır. Diskriminant analizi sonucunda 3 farklı Lineer Diskriminant Fonksiyonu (LDF) elde edilmiştir. LDF'ler için etki değerleri Tablo 7'de verilmiştir.

**Tablo 7.** Kontrast sonrası 30.sn. T1 ağırlıklı görüntüler için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.

<i>Fonksiyon</i>	<i>Eigenvalue (Özdeğer)</i>	<i>Varyansların %’si</i>	<i>Cumulative %</i>	<i>Kanonik Korelasyon Katsayısı</i>
1	9.268	84.0	84.0	0.950
2	1.125	10.2	94.2	0.728
3	0.641	5.8	100.0	0.625

Özdeğerler LDF'lerin hangisinin tahminde kullanılabileceğinin etki derecesini verir. Kontrast sonrası 30.sn. verilerini incelediğimizde 1. LDF için etki derecesi bütün veri setinin %65,1'dir. Veri seti için daha sonra yapılacak değer atama, sınıflama işlemi için en etkili olan 1. LDF kullanılabilir. "Cumulative %" kısmı özdeğer yüzdelerinin toplanmış halidir. Kanonik korelasyon katsayıları ise sınıflama kriter grupları ile değişkenler arasındaki ilişki katsayısıdır. Kanonik korelasyon katsayılarının karesi bağımlı ve bağımsız değişken arasında açıklanan ortak varyansı belirtmektedir. Tablo 7 incelendiğinde 1. LDF için 0,950 (paylaşılan varyansın %90'ı), 2. LDF için 0,728 (paylaşılan varyansın %52'si) ve son LDF için 0,625 (paylaşılan varyansın %39'u) olarak hesaplanmıştır.

Kanonik diskriminant analizi ile belli her bir değişken için farklı katsayılar elde edildi. Değişkenlerin Tablo 7'de gösterilen her bir fonksiyon için elde edilen katsayıları Tablo 8'de izlenmektedir.

**Tablo 8.** Kontrast sonrası 30.sn. T1 ağırlıklı görüntülere ait değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.


	1. Fonksiyon	2. Fonksiyon	3. Fonksiyon
S(0,5)DifEntrp	13.798	-0.295	-3.846
S(0,4)DifEntrp	-11.671	0.752	9.348
S(3,3)DifEntrp	3.134	-7.715	-4.796
S(4,0)DifEntrp	-12.633	-10.468	0.993
S(3,0)DifEntrp	8.391	8.422	-1.096
S(4,-4)DifEntrp	-2.128	-0.688	-2.778
S(4,4)DifEntrp	-4.055	7.155	0.438
S(0,3)DifEntrp	2.085	1.487	-2.167
S(5,0)DifEntrp	3.472	1.380	3.723
WavEnLL_s-1	0.980	0.215	0.532

Elde edilen bu katsayılar, belirli bir olgu için diskriminant puanı hesaplamak üzere kullanılabilir. Skor, standartlaştırılmış katsayılar ve standartlaştırılmış değişkenler kullanılarak doğrusal bir regresyondan tahmin edilen bir değerle aynı şekilde hesaplanır. Standartlaştırma işleminden sonra aşağıda gösterilen Lineer diskriminant fonksiyonları yardımı ile skor hesaplanır. Fonksiyonlar yazılırken standartlaştırılmış değerler olduğu için “z” ifadesi eklenmiştir. Fonksiyonlara ait formüller Tablo 9’da gösterilmiştir.

**Tablo 9.** Kontrast sonrası 30.sn. T1 ağırlıklı görüntülere ait kanonik diskriminant analiz ile oluşturulan her fonksiyon için formüller gösterilmektedir.

LDF1	$=(zS(0,5)DifEntrp)*13,798-(zS(0,4)DifEntrp)*11,671+(zS(3,3)SumEntrp)*3,134$ $-(zS(4,0)DifEntrp)*12,633+(zS(3,0)DifEntrp)*8,391-(zS(4,-4)DifEntrp)*2,128$ $-(zS(4,4)DifEntrp)*4,055+(zS(0,3)DifEntrp)*2,085+(zS(5,0)DifEntrp)*3,472$ $+(zWavEnLH_s-1)*0,980$
LDF2	$=(zS(0,5)DifEntrp)*0,295+(zS(0,4)DifEntrp)*0,752-(zS(3,3)SumEntrp)*7,715$ $-(zS(4,0)DifEntrp)*10,468+(zS(3,0)DifEntrp)*8,422-$ $(zS(4,-4)DifEntrp)*0,688+(zS(4,4)DifEntrp)*7,155+(zS(0,3)DifEntrp)*1,487$ $+(zS(5,0)DifEntrp)*1,380+(zWavEnLH_s-1)*0,215$
LDF3	$=-(zS(0,5)DifEntrp)*3,846+(zS(0,4)DifEntrp)*9,348-(zS(3,3)SumEntrp)*4,796$ $+(zS(4,0)DifEntrp)*0,993-(zS(3,0)DifEntrp)*1,096-(zS(4,-4)DifEntrp)*2,778$ $+(zS(4,4)DifEntrp)*0,438-(zS(0,3)DifEntrp)*2,167+(zS(5,0)DifEntrp)*3,723+(zW$ $avEnLH_s-1)*0,532$

Her bir fonksiyondan alınan puanların dağılımının; bir değer in standart sapması olması ve ortalamasının sıfır olması için standardize edilmiştir. Bu katsayıların büyüklükleri, ayırt edici değişkenlerin puanı ne kadar güçlü etkilediğini göstermektedir. Örneğin, ilk LDF skor hesaplanmasında  $S(0,5)DifEntrp$  için standartlaştırılmış katsayının diğer değişkenlerden (katsayılardan) daha büyük olduğunu görebiliriz. Katsayılarının büyüklükleri diskriminant skoru puanlamasında etki derecesinin sırasını belirler. Böylece, kullanılacak birinci LDF fonksiyonunda atama, sınıflama işlemi yapılabilir.



**Tablo 10.** Kontrast sonrası 30.sn. T1 verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.

	<b>Lezyon Tipi</b>	<b>Berrak Hücreli RHK</b>	<b>Papiller RHK</b>	<b>Kromofob RHK</b>	<b>Onkositom</b>	<b>Toplam</b>
<b>SAYI</b>	Berrak hücreli RHK	11	0	1	0	12
	Papiller	0	3	0	0	3
	Kromofob	0	0	3	0	3
	Onkositom	0	0	0	2	2
<b>%</b>	Berrak hücreli RHK	91,7	0	9,3	0	100
	Papiller	0	100,0	0	0	100
	Kromofob	0	0	100,0	0	100
	Onkositom	0	0	0	100,0	100

Tablo 10 kontrast sonrası 30.sn. T1 ağırlıklı kesitlere ait verilerinin diskriminant analizinin sınıflama sonuçlarını göstermektedir. Kontrast sonrası 30.sn. T1 ağırlıklı görüntülerin tekstür bulgularına göre olguların %95'i doğru sınıflanmıştır.

#### 4.1.2. Kontrast Sonrası 70.sn. T1 Ağırlıklı Kesitlerinin Analizi

Kontrast sonrası 70.sn. T1 ağırlıklı kesitler için çalışılan özelliklerden Fisher katsayısı kullanılarak seçilen özellikler için kanonik diskriminant fonksiyonu uygulanmıştır. Diskriminant analizi sonucunda üç farklı Lineer Diskriminant Fonksiyonu (LDF) elde edilmiştir. LDF'ler için etki değerleri Tablo 11'de verilmiştir.

**Tablo 11.** Kontrast sonrası 70.sn T1 ağırlıklı görüntüler için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.

<b>Fonksiyon</b>	<b>Eigenvalue (Özdeğer)</b>	<b>Varyansların %'si</b>	<b>Cumulative %</b>	<b>Kanonik Korelasyon Katsayısı</b>
<b>1</b>	5,965	65,1	65,1	0,925
<b>2</b>	2,105	23,0	88,1	0,823
<b>3</b>	1,093	11,9	100	0,723

Kontrast sonrası 70.sn. T1 ağırlıklı görüntülerinin kanonik diskriminant analizine göre elde edilen 1. LDF için etki derecesi bütün veri seti için %65,1'dir. Veri seti için daha sonra yapılacak değer atama, sınıflama işlemi için en etkili olan 1. LDF kullanılabilir. "Cumulative %" kısmı özdeğerlerin yüzdelerin toplanmış halidir. Kanonik korelasyon katsayıları ise sınıflama kriter grupları ile değişkenler arasındaki ilişki katsayısıdır. Kanonik korelasyon katsayılarının karesi bağımlı ve bağımsız değişken arasında açıklanan ortak varyansı belirtmektedir. Tablo 11 incelendiğinde 1. LDF için 0,925(paylaşılan varyansın %85'i), 2. LDF için 0,823 (paylaşılan varyansın %67'si) ve son LDF için 0,723 (paylaşılan varyansın %52'si) olarak hesaplanmıştır.

Diskriminant analizi ile belli her bir değişken için farklı katsayılar elde edilmektedir. Yukarıdaki tabloda belirttiğimiz her bir fonksiyon için elde edilen kat sayılar Tablo 12'de gösterilmiştir.

**Tablo 12.** Kontrast sonrası 70.sn. T1 ağırlıklı görüntülere ait değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.

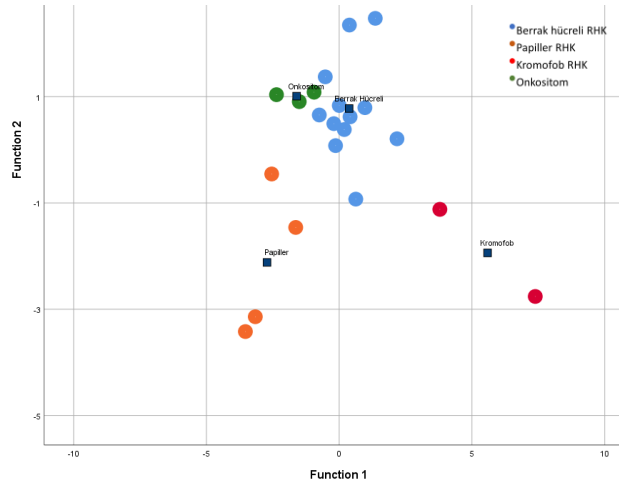
	4. Fonksiyon	5. Fonksiyon	6. Fonksiyon
WavEnLL_s-3	1,377	-0,141	-0,002
Variance	-0,208	0,746	0,042
S(0,1)DifEntrp	-3,003	-1,348	-3,029
45dgr_LngREmph	-0,178	-0,287	0,923
S(3,-3)DifEntrp	2,375	-1,968	5,394
WavEnHH_s-2	0,742	0,673	0,831
S(2,0)SumOfSqs	0,659	-0,525	-0,741
S(4,-4)DifEntrp	-0,498	3,266	-2,947
WavEnLH_s-4	-0,600	0,441	-0,025
Vertl_ShrtREmp	1,568	0,317	1,349

Elde edilen bu kat sayılara göre oluşturulan fonksiyon formülleri Tablo 13'te gösterilmiştir. Formüller kullanılarak her bir değer için fonksiyonlar skorlanabilir. Fonksiyonlar yazılırken standartlaştırılmış değerler olduğu için "z" ifadesi eklenmiştir.

**Tablo 13.** Kontrast sonrası 70.sn. T1 ağırlıklı görüntülere ait kanonik diskriminant analiz ile oluşturulan her fonksiyon için formüller gösterilmektedir.

LDF1	$=(zWavEnLL\_s3)*1,377-(zVariance)*0,208-(zS(0,1)DifEntrp)*3,003$ $-(z45dgr\_LngREmph)*0,178+(zS(3,-3)DifEntrp)*2,375+(zWavEnHH\_s2)*0,742$ $+(zS(2,0)SumOfSqs)*0,659-(zS(4,-4)DifEntrp)*0,498$ $-(zWavEnLH\_s4)*0,6+(zVertl\_ShrtREmp)*1,568$
LDF2	$=-(zWavEnLL\_s3)*0,141+(zVariance)*0,746-(zS(0,1)DifEntrp)*1,348$ $-(z45dgr\_LngREmph)*0,287-(zS(3,-3)DifEntrp)*1,968$ $+(zWavEnHH\_s2)*0,673-(zS(2,0)SumOfSqs)*0,525$ $+(zS(4,-4)DifEntrp)*3,266+(zWavEnLH\_s4)*0,441+(zV ertl\_ShrtREmp)*0,317$
LDF3	$=-(zWavEnLL\_s3)*0,002+(zVariance)*0,042-(zS(0,1)DifEntrp)*3,029$ $+(z45dgr\_LngREmph)*0,923+(zS(3,-3)DifEntrp)*5,394$ $+(zWavEnHH\_s2)*0,831-(zS(2,0)SumOfSqs)*0,741-(zS(4,-4)DifEntrp)*2,947$ $-(zWavEnLH\_s4)*0,025+(zV ertl\_ShrtREmp)*1,349$

İlk LDF skor hesaplanmasında S(0,1)DifEntrp için standartlaştırılmış katsayının diğer değişkenlerden (katsayılarından) daha büyük olduğunu görülebilir. Kat sayısının büyük oluşu diskriminant fonksiyonunda daha önemli bir yere ait olduğunu göstermektedir.



**Şekil 11.** Kontrast sonrası 70.sn. T1 ağırlıklı görüntülerinin sınıflama sonuçlarına ait grafik.

LDF1 (X eksen) ve LDF2 (Y eksen) fonksiyonları kullanılarak oluşan sonuçta grupların dağılımı izlenmektedir. Grup merkezleri mavi kareler ile gösterilmiştir. Berrak hücreli RHK'ler mavi, Papiller RHK'ler turuncu, Kromofob RHK'ler kırmızı, Onkositomlar yeşil dairelerle gösterilmiştir.

Yapılan diskriminant analizi sonucunda grafik çıktısı ile grupların dağılımı ve grup merkezleri Şekil 11’de gösterilmiştir. X ve Y eksenine ise LDF’ler ve bunlardan elde edilen skorlar yardımıyla belirlenmiştir. İlk iki LDF kullanılarak harita çizilmiştir. Berrak hücreli RHK ve onkositom kategorileri davranışsal olarak birbirine benzer karakteristikler göstermektedir. Küme merkezlerinin birbirine yakın oluşu sınıflama yaparken dikkat edilmesi gereken bir detaydır. Kromofob RHK’lerin ise kontrast sonrası T1A görüntülerdeki tekstür özelliklerinin genel olarak diğer gruplardan uzakta, daha benzemez bir yapıda olduğu görülmektedir.

**Tablo 14.** Kontrast sonrası 70.sn. T1 verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.

	<b>Lezyon Tipi</b>	<b>Berrak Hücreli RHK</b>	<b>Papiller RHK</b>	<b>Kromofob RHK</b>	<b>Onkositom</b>	<b>Toplam</b>
<b>SAYI</b>	Berrak hücreli RHK	12	0	0	0	12
	Papiller	0	4	0	0	4
	Kromofob	0	0	2	0	2
	Onkositom	0	0	0	3	3
<b>%</b>	Berrak hücreli RHK	100.0	0	0	0	100
	Papiller	0	100.0	0	0	100
	Kromofob	0	0	100.0	0	100
	Onkositom	0	0	0	100.0	100

Tablo 14 kontrast sonrası 70.sn. T1 ağırlıklı görüntülere ait verilerin diskriminant analizinin sınıflama sonuçlarını göstermektedir. Bu verilere ait tekstür bulgularına göre olguların %100’ü doğru sınıflanmıştır.

#### 4.1.3. T2 Kesitlerinin Analizi

T2 ağırlıklı kesitlere ait veriler özellikler seçme ve azaltma yöntemleri arasında farklılık olup olmadığını değerlendirmek için hem Fisher katsayısı hem de POE+ACC yöntemi kullanılarak ayrı ayrı seçilerek analiz edildi. POE+ACC yöntemiyle özellik seçim ve azaltma işlemleri, 8bit/piksele (256 grilik seviyesi) ve 6bit/piksel (64 grilik seviyesi) indirgenen verilerde ayrı ayrı çalışıldı. Seçilen özellikler için kanonik diskriminant analizi uygulandı. Diskriminant analizi



sonucunda üç farklı Lineer Diskriminant Fonksiyonu (LDF) elde edildi. LDF'ler için etki değerleri Tablo 15'te verilmiştir.

**Tablo 15.** T2 ağırlıklı görüntüler için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.

Fonksiyon		Eigenvalue (Özdeğer)	Varyansların %’si	Cumulative %	Kanonik Korelasyon Katsayısı
<b>FISHER</b> 8bit/piksel	<b>1</b>	15,158	75,2	75,2	<b>0,969</b>
	<b>2</b>	3,375	16,7	91,9	0,878
	<b>3</b>	1,624	8,1	100,0	0,787
<b>POE+ACC</b> 8bit/piksel	<b>a</b>	20,144	82,1	82,1	<b>0,976</b>
	<b>b</b>	3,689	15,0	97,1	0,887
	<b>c</b>	0,706	2,9	100,0	0,643
<b>POE+ACC</b> 6bit/piksel	<b>x</b>	3,852	56,5	56,5	<b>0,891</b>
	<b>y</b>	1,892	27,7	84,2	0,809
	<b>z</b>	1,077	15,8	100,0	0,720

T2 ağırlıklı görüntülerde 8bit/piksele indirgenip Fisher katsayısı ile seçilen verilerde LDF1 etki derecesi bütün veri setinde %75,2’dir. Kanonik Korelasyon katsayısı LDF1 için 0,969(paylaşılan varyansın %93’ü) olarak hesaplanmıştır.

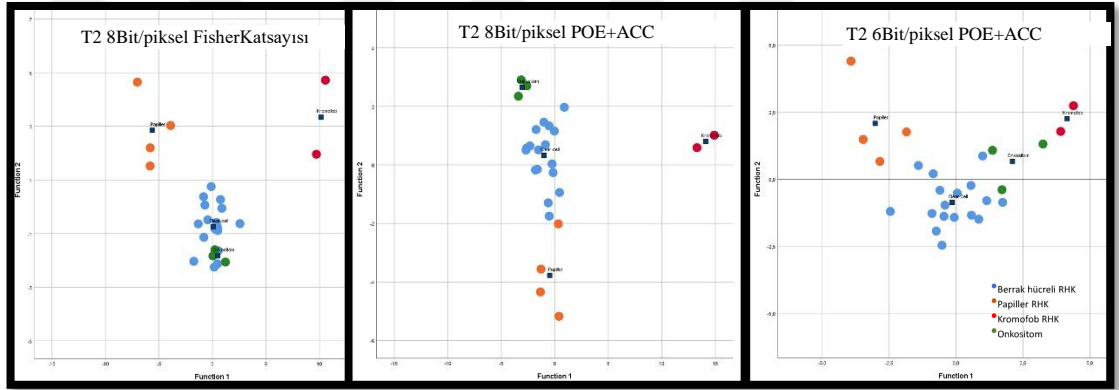
T2 ağırlıklı görüntülerde 8bit/piksele indirgenip POE+ACC ile seçilen veriler için LDFa etki derecesi bütün veri setinde %82’dir. Kanonik Korelasyon katsayısı LDFa için 0,976(paylaşılan varyansın %95’i) olarak hesaplanmıştır.

T2 ağırlıklı görüntülerde 6bit/piksele indirgenip POE+ACC ile seçilen verilerde LDFx etki derecesi bütün veri seti için %56,5’dir. Kanonik Korelasyon katsayısı LDFx için 0,891(paylaşılan varyansın %79’u) olarak hesaplanmıştır.

Diskriminant analizi ile her fonksiyona ait değişkenler için elde edilen kat sayılar Tablo 16’da gösterilmiştir.

**Tablo 16.** T2 verileri için belirlenen fonksiyonlara göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.

	Fisher 8bit/piksel		POE+ACC 8bit/piksel		POE+ACC 6bit/piksel			
	LDF1	LDF2	LDFa	LDFb	LDFx	LDFy		
<i>S(3,3)InvDfMom</i>	-0,373	1,737	<i>WavEnHH_s-4</i>	2,596	-0,365	<i>S(4,4)DifEntrp</i>	0,467	-,154
<i>S(5,0)SumOfSqs</i>	1,493	0,191	<i>S(5,5)AngScMom</i>	-4,566	0,576	<i>GrSkewness</i>	0,306	0,036
<i>WavEnLH_s-4</i>	1,254	-0,200	<i>WavEnHL_s-4</i>	0,453	0,199	<i>S(2,2)Entropy</i>	4,770	0,558
<i>WavEnLL_s-3</i>	0,478	0,503	<i>S(3,3)InvDfMom</i>	0,525	-0,996	<i>S(5,5)SumOfSqs</i>	0,689	0,080
<i>S(2,-2)SumOfSqs</i>	0,104	0,032	<i>S(5,-5)AngScMom</i>	5,158	-0,136	<i>WavEnHL_s4</i>	-0,004	0,154
<i>S(2,0)InvDfMom</i>	-1,948	-0,920	<i>S(5,5)Entropy</i>	-1,735	-2,970	<i>S(0,4)Entropy</i>	-7,713	-3,773
<i>Teta2</i>	-0,379	0,709	<i>S(5,-5)SumOfSqs</i>	-0,378	0,648	<i>S(0,3)Entropy</i>	5,570	1,379
<i>S(4,0)SumOfSqs</i>	0,032	-0,158	<i>S(0,4)Entropy</i>	0,571	10,764	<i>Skewness</i>	-0,277	0,025
<i>S(3,-3)SumOfSqs</i>	-0,303	-0,272	<i>S(3,0)Entropy</i>	1,009	-7,877	<i>S(2,0)Entropy</i>	-2,968	1,237
<i>S(4,-4)InvDfMom</i>	1,548	-0,827	<i>GrSkewness</i>	0,050	0,660	<i>Teta2</i>	-0,058	0,731



**Şekil 12.** T2 Verilerinin analizine ait grafikler izlenmektedir.

Grup merkezleri mavi kareler ile gösterilmiştir. Berrak hücreli RHK'ler mavi, Papiller RHK'ler turuncu, Kromofob RHK'ler kırmızı, Onkositomlar yeşil dairelerle gösterilmiştir.

Yapılan diskriminant analizi sonucunda her üç veri seti için grafik çıktısı ile grupların dağılımı ve grup merkezleri Şekil 12'de gösterilmiştir. Üç analizin sonucunda da Berrak hücreli RHK ve onkositom kategorileri davranışsal olarak birbirine benzer karakteristikler göstermektedir. Küme merkezlerinin birbirine yakın oluşu sınıflama yaparken dikkat edilmesi gereken bir detaydır. Yine üç analizde de kromofob RHK'lerin T2 ağırlıklı görüntülerine ait tekstür özelliklerinin genel olarak diğer gruplardan uzakta, daha benzemez bir yapıda olduğu görülmektedir. Gruplar arasındaki ayırıcılık fonksiyonu en iyi Fisher 8bit/piksel grubunda izlenmektedir.

**Tablo 17.** T2 verilerinin üç ayrı gruba göre sınıflama sonuçları gösterilmektedir.

	<b>Lezyon Tipi</b>	<b>Berrak Hücreli RHK</b>	<b>Papiller RHK</b>	<b>Kromofob RHK</b>	<b>Onkositom</b>	<b>Toplam</b>
<b>FISHER 8bit/piksel LDF1</b>	Berrak hücreli RHK	17	0	0	0	17
	Papiller	0	4	0	0	4
	Kromofob	0	0	2	0	2
	Onkositom	0	0	0	3	3
<b>POE+ACC 8bit/piksel LDFa</b>	Berrak hücreli RHK	16	0	0	1	17
	Papiller	0	4	0	0	4
	Kromofob	0	0	2	0	2
	Onkositom	0	0	0	3	3
<b>POE+ACC 6bit/piksel LDFx</b>	Berrak hücreli RHK	16	0	0	1	17
	Papiller	0	4	0	0	4
	Kromofob	0	0	2	0	2
	Onkositom	0	0	0	3	3

Tablo 17’de üç ayrı grubun sınıflama sonuçları da verilmiştir. 8bit/piksel verilerinde Fisher yöntemiyle seçilen verilerin %100’ü doğru sınıflanmıştır. Hem 8bit/piksel hem de 6bit/piksel POE+ACC yöntemiyle seçilen verilerin %96,2’si doğru sınıflanmıştır.

#### 4.1.4. SPAIR T2 Kesitlerinin Analizi

SPAIR T2 kesitlerden Fisher katsayısı kullanılarak seçilen özellikler için kanonik diskriminant analizi uygulanmıştır. Diskriminant analizi sonucunda üç farklı Lineer Diskriminant Fonksiyonu (LDF) elde edilmiştir. LDF’ler için etki değerleri Tablo 18’de verilmiştir.

**Tablo 18.** SPAIR T2 görüntüler için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.


<b>Fonksiyon</b>	<b>Eigenvalue (Özdeğer)</b>	<b>Varyansların %’si</b>	<b>Cumulative %</b>	<b>Kanonik Korelasyon Katsayısı</b>
<b>1</b>	2,259	57,9	57,9	0,833
<b>2</b>	1,190	30,5	88,4	0,737
<b>3</b>	0,453	11,6	100,0	0,559

SPAIR T2 verileri için 1. LDF için etki derecesi bütün veri setinde %57,9'dur. Veri seti için daha sonra yapılacak değer atama, sınıflama işleminde en etkili olan 1. LDF kullanılabilir. Kanonik korelasyon katsayısı 1. LDF için 0,833 (paylaşılan varyansın %69'u), 2. LDF için 0,737 (paylaşılan varyansın %54'ü) ve son LDF için 0,559 (paylaşılan varyansın %31'i) olarak hesaplanmıştır.

Diskriminant analizi ile belli her bir değişken için farklı katsayılar elde edilmektedir. Yukarıdaki tabloda belirtilen her bir fonksiyon için elde edilen kat sayılar Tablo 19'da gösterilmiştir.

**Tablo 19.** SPAIR T2 verileri için belirlenen fonksiyonlara göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.

	1.Fonksiyon	2.Fonksiyon	3.Fonksiyon
WavEnLL_s-4	1,452	-0,458	-0,123
WavEnLL_s-3	-0,671	1,303	0,199
WavEnHH_s-1	0,930	0,070	-0,815
S(5,0)InvDfMom	0,300	-0,280	0,412
WavEnHH_s-2	-1,393	0,287	-0,546
S(0,5)DifVarnc	-5,805	2,974	0,578
S(0,4)DifVarnc	6,689	-2,611	-0,133
S(3,-3)DifVarnc	0,203	-0,792	0,311
S(1,1)Contrast	-,729	0,932	0,751
WavEnLL_s-4	1,452	-0,458	-0,123



**Şekil 13.** SPAIR T2 görüntülerinin sınıflama sonuçlarına ait grafik.

LDF1 (X eksen) ve LDF2 (Y eksen) fonksiyonları kullanılarak oluşan sonuçta grupların dağılımı izlenmektedir. Grup merkezleri mavi kareler ile gösterilmiştir. Berrak hücreli RHK'ler mavi, Papiller RHK'ler turuncu, Kromofob RHK'ler kırmızı, Onkositomlar yeşil dairelerle gösterilmiştir.

Yapılan diskriminant analizi sonucunda grafik çıktısı ile grupların dağılımı ve grup merkezleri Şekil 13'te gösterilmiştir. Berrak hücreli RHK ve papiller RHK kategorileri davranışsal olarak birbirine benzer karakteristikler göstermektedir. Küme merkezlerinin birbirine yakın oluşu sınıflama yaparken dikkat edilmesi gereken bir detaydır. Kromofob RHK'ler ve onkositomların ise SPAIR T2 ağırlıklı görüntülerdeki tekstür özelliklerinin genel olarak diğer gruplardan uzakta, daha benzemez bir yapıda olduğu görülmektedir.

**Tablo 20.** SPAIR T2 verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.

	Lezyon Tipi	Berrak Hücreli RHK	Papiller RHK	Kromofob RHK	Onkositom	Toplam
SAYI	Berrak hücreli RHK	18	0	1	0	19
	Papiller	1	2	0	0	3
	Kromofob	0	0	3	0	3
	Onkositom	1	0	0	2	3
%	Berrak hücreli RHK	94,7	0,0	5,3	0,0	100,0
	Papiller	33,3	66,7	0,0	0,0	100,0
	Kromofob	0,0	0,0	100	0,0	100,0
	Onkositom	33,3	0,0	0,0	66,7	100,0

Tablo 20'de SPAIR T2 verilerinin diskriminant analizinin sınıflama sonuçları gösterilmektedir. Tekstür bulgularına göre olguların %89,3'ü doğru sınıflanmıştır.

#### 4.1.5. Dış Faz (out of phase) Kesitlerinin Analizi

Dış faz kesitlerinde Fisher katsayısı kullanılarak seçilen özellikler için kanonik diskriminant analizi uygulanmıştır. Diskriminant analizi sonucunda üç farklı Lineer Diskriminant Fonksiyonu (LDF) elde edilmiştir. LDF'ler için etki değerleri Tablo 21'de verilmiştir.

**Tablo 21.** Dış faz görüntülerde kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.


Fonksiyon	Eigenvalue (Özdeğer)	Varyansların %'si	Cumulative %	Kanonik Korelasyon Katsayısı
1	6.298	85.5	85.5	0.929
2	0.896	12.2	97.7	0.688
3	0.168	2.3	100.0	0.379

Dış faz kesitlerine ait verilerde 1. LDF için etki derecesi bütün veri setinde %85,5'dir. Veri setinde daha sonra yapılacak değer atama, sınıflama işlemi için en etkili olan 1. LDF kullanılabilir. Kanonik korelasyon katsayısı 1. LDF için 0,929 (paylaşılan varyansın %86'sı), 2. LDF için 0,688 (paylaşılan varyansın %47'si) ve son LDF için 0,379 (paylaşılan varyansın %14'ü) olarak hesaplanmıştır.

Diskriminant analizi ile belli her bir değişken için farklı katsayılar elde edilmiştir. Yukarıdaki tabloda belirtilen her bir fonksiyon için elde edilen kat sayılar Tablo 22'de gösterilmiştir.

**Tablo 22.** Dış faz kesitlerine ait veriler için belirlenen fonksiyonlara göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.

	1. Fonksiyon	2. Fonksiyon	3. Fonksiyon
S(2,0)InvDfMom	0.686	-0.892	0.597
S(1,0)InvDfMom	4.716	0.809	-1.290
S(3,0)InvDfMom	-5.895	-0.876	1.699
S(5,0)InvDfMom	3.075	-0.248	-0.606
Teta4	0.855	-0.387	-0.789
S(4,0)InvDfMom	-.538	0.643	0.148
Horzl_LngREmph	6.512	2.540	-0.059
S(0,5)InvDfMom	-0.333	0.053	0.674
Horzl_Fraction	8.175	1.904	0.240
WavEnLL_s-3	0.103	-0.826	-0.031



**Şekil 14.** Dış faz görüntülerinin sınıflama sonuçlarına ait grafik.

LDF1 (X eksen) ve LDF2 (Y eksen) fonksiyonları kullanılarak oluşan sonuçta grupların dağılımı izlenmektedir. Grup merkezleri mavi kareler ile gösterilmiştir. Berrak hücreli RHK'ler mavi, Papiller RHK'ler turuncu, Kromofob RHK'ler kırmızı, Onkositomlar yeşil dairelerle gösterilmiştir.

Yapılan diskriminant analizi sonucunda grafik çıktısı ile grupların dağılımı ve grup merkezleri Şekil 14'te gösterilmiştir. Berrak hücreli RHK ve onkositom kategorileri davranışsal olarak birbirine benzer karakteristikler göstermektedir. Kromofob RHK'lerin ve papiller RHK'lerin dış faz görüntülerdeki tekstür özelliklerinin genel olarak diğer gruplardan uzakta, daha benzemez bir yapıda olduğu görülmektedir.

**Tablo 23.** Dış faz verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.

	<b>Lezyon Tipi</b>	<b>Berrak Hücreli RHK</b>	<b>Papiller RHK</b>	<b>Kromofob RHK</b>	<b>Onkositom</b>	<b>Toplam</b>
<b>SAYI</b>	Berrak hücreli RHK	19	0	0	1	20
	Papiller	0	4	0	0	4
	Kromofob	1	0	2	0	3
	Onkositom	0	0	0	3	3
<b>%</b>	Berrak hücreli RHK	95,0	0,0	5,3	5,0	100,0
	Papiller	0,0	100	0,0	0,0	100,0
	Kromofob	33,3	0,0	66,6	0,0	100,0
	Onkositom	0	0,0	0,0	100	100,0

Tablo 23'te SPAIR T2 verilerinin diskriminant analizinin sınıflama sonuçları gösterilmektedir. Tekstür bulgularına göre olguların %93,3'ü doğru sınıflanmıştır.

#### 4.1.6. ADC Kesitlerinin Analizi

Seçilen özellikler için kanonik diskriminant fonksiyonu uygulanmıştır. Diskriminant analizi sonucunda 3 farklı Lineer Diskriminant Fonksiyonu (LDF) elde edilmiştir. LDF'ler için etki değerleri Tablo 24'te verilmiştir.

**Tablo 24.** ADC kesitleri için kanonik diskriminant analiziyle belirlenen üç fonksiyonun özdeğer verileri listelenmiştir.


<b>Fonksiyon</b>	<b>Eigenvalue (Özdeğer)</b>	<b>Varyansların %'si</b>	<b>Cumulative %</b>	<b>Kanonik Korelasyon Katsayısı</b>
<b>1</b>	1,386	58,2	58,2	0,762
<b>2</b>	0,582	24,5	82,7	0,606
<b>3</b>	0,412	17,3	100,0	0,540

Bu çalışmada 1. LDF için etki derecesi bütün veri seti için %58,2'dir. Veri seti için daha sonra yapılacak değer atama, sınıflama işlemi için en etkili olan 1. LDF kullanılabilir.

Yukarıdaki tabloda belirttiğimiz her bir fonksiyon için elde edilen kat sayılar Tablo 25'te gösterilmiştir.

**Tablo 25.** ADC kesitleri için belirlenen fonksiyonlara göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir.

	1. Fonsiyon	2. Fonksiyon	3. Fonksiyon
S(0,2)DifVarnc	0,702	0,190	1,172
WavEnHL_s-3	0,042	-0,532	0,351
S(5,5)SumEntrp	2,247	-0,289	0,024
Variance	-1,907	0,520	-0,085
S(5,-5)AngScMom	-0,009	-1,881	-4,721
S(4,0)SumVarnc	-0,547	0,610	-0,031
S(4,-4)AngScMom	1,369	2,622	4,758
WavEnLL_s-1	0,385	-0,029	-0,202
S(5,5)Correlat	0,119	0,184	1,330
WavEnLH_s-3	0,245	0,375	-0,222



**Şekil 15.** ADC görüntülerinin sınıflama sonuçlarına ait grafik

LDF1 (X eksen) ve LDF2 (Y eksen) fonksiyonları kullanılarak oluşan sonuçta grupların dağılımı izlenmektedir. Grup merkezleri mavi kareler ile gösterilmiştir. Berrak hücreli RHK'ler mavi, Papiller RHK'ler turuncu, Kromofob RHK'ler kırmızı, Onkositomlar yeşil dairelerle gösterilmiştir.



Yapılan diskriminant analizi sonucunda grafik çıktısı ile ADC özellikleri açısından grupların dağılımı ve grup merkezleri Şekil 15'te gösterilmiştir. Berrak hücreli RHK ve onkositom kategorileri davranışsal olarak birbirine benzer karakteristikler göstermektedir. Papiller RHK olgularının da davranışı benzerlik göstermektedir. Kromofob RHK olgularının tekstür özellikler diğer gruplardan uzakta, daha benzemez bir yapıda olduğu görülmektedir.

**Tablo 26.** ADC verilerinin LDF1'e göre sınıflama sonuçları gösterilmektedir.

	<b>Lezyon Tipi</b>	<b>Berrak Hücreli RHK</b>	<b>Papiller RHK</b>	<b>Kromofob RHK</b>	<b>Onkositom</b>	<b>Toplam</b>
<b>SAYI</b>	Berrak hücreli RHK	15	0	1	3	19
	Papiller	0	1	1	3	5
	Kromofob	0	0	2	0	2
	Onkositom	1	0	0	2	3
<b>%</b>	Berrak hücreli RHK	78,9	0,0	5,3	15,8	100
	Papiller	0,0	60,0	20,0	20,0	100
	Kromofob	0,0	0	100	0	100
	Onkositom	33,3	0	0	66,7	100

Tablo 26'da ADC verilerinin diskriminant analizinin sınıflama sonuçlarını göstermektedir. ADC görüntülerin tekstür bulgularına göre olguların %75,9'u doğru sınıflanmıştır.

#### **4.2. NÜKLEER GRADE-TEKSTÜR ÖZELLİKLERİ İLİŞKİSİNİN DEĞERLENDİRİLMESİ**

Çalışmanın en kalabalık grubu olan berrak hücreli RHK olgularında daha sonra tekstür analizi özelliklerinin Fuhrman nükleer evresi ile ilişkisi de değerlendirildi. 21 Berrak hücreli olgunun 20'sinin histopatolojik olarak Fuhrman evre bilgisi mevcuttur. Olguların 1'i evre 1, 9'u evre 2, 8'i evre 3, 2si evre 4'tü. Olguların cinsiyetlere göre dağılımı Tablo 27'de listelenmiştir.

**Tablo 27.**Berrak hücreli RHK olgularının cinsiyet ve Fuhrman nükleer evresine göre listesi.

Fuhrman Nükleer Evresi	Erkek	Kadın	Toplam
Evre 1	1	0	1
Evre 2	7	2	9
Evre 3	5	3	8
Evre 4	2	0	2

Olgu sayısının az oluşu nedeniyle olgular düşük evre ve yüksek evre olarak iki sınıfa ayrılarak incelenmiştir. Bu düzenlemeyle literatürde de örnekleri bulunduğu şekliyle “Evre 1” ve “evre 2” olgular düşük evre, “evre 3” ve “evre 4” olgular yüksek evre olarak kabul edilmiştir. Olgulara ait T2 ağırlıklı görüntüler, kontrast sonrası 70.sn. T1 ağırlıklı görüntüler ve ADC görüntüleri MaZda programı ile tekstür özellikleri açısından analiz edildi. Her MR sekansındaki veri grupları için seçilen özelliklerde ayırt edici gücü en yüksek 10 özellik Fisher Katsayısı kullanılarak seçildi. Seçilen özelliklerin ayırıcı fonksiyonu kanonik diskriminant analizi ile değerlendirildi.

Her sekansda seçilen özellikler için yüksek evre-düşük evre ayırımına yönelik kanonik diskriminant fonksiyonu uygulanmıştır. Diskriminant analizi sonucunda Her sekans için Lineer Diskriminant Fonksiyonu (LDF) elde edilmiştir. LDF’ler için etki değerleri Tablo 28’de verilmiştir.

**Tablo 28.**Berrak hücreli RHK olgularının düşük grade-yüksek grade ayırımına yönelik kanonik diskriminant analiziyle belirlenen kontrast sonrası 70.sn. T1 ağırlıklı, T2 ağırlıklı ve ADC görüntüleri için fonksiyonların özdeğer verileri listelenmiştir.

Fonksiyon	Eigenvalue (Özdeğer)	Varyansların %'si	Cumulative %	Kanonik Korelasyon Katsayısı
<b>LDF- TIC</b>	163.488	100.0	100.0	0.997
<b>LDF-T2</b>	4.258	100.0	100.0	0.900
<b>LDF-ADC</b>	11.446	100.0	100.0	0.959

Berrak hücreli RHK olgularının yüksek evre-düşük evre ayırımına yönelik incelendiğinde kontrast sonrası 70. sn. T1 ağırlıklı görüntüler için seçilen özelliklerin 1. fonksiyonunun (**LDF-TIC**) etki derecesi bütün veri seti için %100’dür. Kanonik

korelasyon katsayısı *LDF-T1C* için değer 0,997 (paylaşılan varyansın %99'u), T2 ağırlıklı görüntüler için seçilen özelliklerin 1. fonksiyonunun (*LDF-T2*) etki derecesi bütün veri seti için %100'dür. Kanonik korelasyon katsayısı *LDF-T2* için değer 0,900 (paylaşılan varyansın %81'i), ADC görüntüler için seçilen özelliklerin 1. fonksiyonunun (*LDF-ADC*) etki derecesi bütün veri seti için %100'dür. Kanonik korelasyon katsayısı *LDF-ADC* için değer 0,959 (paylaşılan varyansın %92'si) olarak hesaplanmıştır.

Diskriminant analizi ile her bir fonksiyon için elde edilen değişkenlere ait katsayılar Tablo 29'da gösterilmiştir. *LDF-T2* için gruplar arasında tam doğrusallığa yakın ilişki bulunan iki değişken ("S(3,-3)SumAverg" ve "S(0,3)SumAverg) varsayımlar ve modelin uyumu açısından çıkarılmıştır. Lineer/doğrusal ilişki, bağımsız değişkenler arasında tam doğrusal (ya da tam doğrusala yakın) ilişki olmasıdır. Uygulamada daha çok, uç haller arasındaki durumlarla karşılaşılmakta ve değişkenler arasındaki önemli derecede bir ilişki, problem olarak karşımıza çıkmaktadır. Bu doğrusal ilişkili değişkenlerin tespiti çoklu doğrusal bağlantı testi olan VIF (Variance Inflation Factor) ile tespiti yapılmıştır. Pearson korelasyon testi ile verilerin doğrulanması yapılmıştır. Pearson korelasyon katsayısı 0,987 bulunarak bu iki değişken arasında tam doğrusala yakın ilişki olduğu tespit edilmiştir.

**Tablo 29.** Düşük evre-yüksek evre ayırımına yönelik her üç sekans için belirlenen fonksiyona göre değişkenlerin standardize edilmiş kanonik diskriminant fonksiyon katsayıları gösterilmektedir

Kontrast Sonrası 70.sn. T1		T2		ADC	
LDF-T1C		LDF-T2		LDF-ADC	
WavEnHL_s-4	6.386	WavEnLL_s-3	-1.686	WavEnLL_s-2	-1.835
S(1,-1)DifVarnc	-6.750	S(1,-1)SumAverg	1.451	WavEnLL_s-3	1.113
Kurtosis	3.502	S(2,-2)SumAverg	3.836	WavEnLL_s-1	2.110
S(2,-2)DifVarnc	1.331	S(0,2)SumAverg	-2.050	WavEnLL_s-4	2.051
WavEnLH_s-4	-0.857	S(0,1)SumAverg	2.527	WavEnLH_s-3	0.226
S(2,-2)InvDfMom	3.940	WavEnLL_s-4	1.190	Perc.01%	-2.486
GrKurtosis	-6.334	S(1,1)SumAverg	-6.659	S(2,2)InvDfMom	3.493
S(1,-1)Contrast	4.014	S(1,0)SumAverg	1.543	S(3,3)InvDfMom	-3.278
S(1,-1)Correlat	1.492			Perc.10%	2.308
WavEnLL_s-3	3.395			S(0,3)SumAverg	0.690

Fonksiyonlardan elde edilen bu katsayılar (Tablo 29) ile belirlenen formüller Tablo 30’da gösterilmiştir.

**Tablo 30.** Nükleer evre ilişkisine yönelik Kanonik Diskriminant Analizi ile ADC, T2 ve kontrast sonrası 70.sn. T1, sekanslarında oluşturulan fonksiyonlara ait formüller gösterilmektedir.

<b>LDF-T1C</b>	$=(WavEnHL\_s-4)*6,386-(S(1,-1)DifVarnC)*6,750+(Kurtosis)*3,502$ $+(S(2,-2)DifVarnC)*1,331-(WavEnLH\_s-4)*0,857$ $+(S(2,-2)InvDfMom)*3,940-(GrKurtosis)*6,334$ $+(S(1,-1)Contrast)*4,014+(S(1,-1)Correlat)*1,492$ $+(WavEnLL\_s-3)*3,395$
<b>LDF-T2</b>	$=-(WavEnLL\_s-3)*1,686+(S(1,-1)SumAverg)*1,451$ $+(S(2,-2)SumAverg)*3,836-(S(0,2)SumAverg)*2,050$ $+(S(0,1)SumAverg)*2,527+(WavEnLL\_ -4)*1,190$ $-(S(1,1)SumAverg)*6,659+(S(1,0)SumAverg)*1,543$
<b>LDF-ADC</b>	$=-(WavEnLL\_s-2)*1,835+(WavEnLL\_s-3)*1,113$ $+(WavEnLL\_s-1)*2,110-(WavEnLL\_s-4)*2,051$ $+(WavEnLH\_s-3)*0,226-(Perc.01%)*2,486+(S(2,2)InvDfMom)*3,493$ $-(S(3,3)InvDfMom)*3,278+(Perc.10%)*2,308$ $+(S(0,3)SumAverg)*0,690$


Tablo 31’de üç ayrı sekansın sınıflama sonuçları verilmiştir. Hareket artefaklı sekansların değerlendirme dışında bırakılması nedeniyle sınıflama gruplarındaki olgu sayıları farklıdır. Kontrast sonrası 70.sn. T1 ağırlıklı kesitler için 13 hastaya (7 düşük evre, 6 yüksek evre), T2 ağırlıklı kesitleri için 16 hastaya (7 düşük evre, 9 yüksek evre), ADC kesitleri için 19 hastaya (10 düşük evre, 9 yüksek evre) ait veriler mevcuttur. T1 ağırlıklı serilerde ve ADC kesitlerinde seçilen verilerin %100’ü doğru sınıflanmıştır. T2 ağırlıklı görüntülerde olguların %93,8’i doğru sınıflanmıştır.

**Tablo 31.** Düşük nükleer evre – yüksek nükleer evre verilerinin üç ayrı sekansa sınıflama sonuçları gösterilmektedir.

	<b>Lezyon Tipi</b>	<b>Düşük evre</b>	<b>Yüksek Evre</b>	<b>Toplam</b>
<b>Kontrast Sonrası 70.Sn T1</b>	Düşük evre	7(%100)	0	7
	Yüksek evre	0	6(%100)	6
<b>T2</b>	Düşük evre	6(%86)	1(%14)	7
	Yüksek evre	0	9	9
<b>ADC</b>	Düşük evre	10(%100)	0	10
	Yüksek evre	0	9(%100)	9

## 5. OLGU ÖRNEKLERİ


**Olgu 1:** 61 yaşında kadın Berrak hücreli RHK olgusu (Şekil 16).



**Şekil 16.** Berrak hücreli RHK olgusunun sağ böbrek alt kesim anteriorunda 61x58mm boyutlu lezyon izlenmektedir.

(A) T2 ağırlıklı görüntü ve (B)'deki manüel olarak çizilen ROI'si ile (C) T2 SPAIR görüntü ve (D)'deki ROI'si izlenmektedir.


**Olgu 2:** 88 yaşında kadın Kromofob RHK olgusu (Şekil 17).



**Şekil 17.** Kromofob RHK olgusunun sağ böbrek üst kesim lateralindeki 42x35mm boyutlu lezyon izlenmektedir.

(A) dış faz görüntüsü ve (B)'deki manüel olarak çizilen ROI'si ile (C) ADC görüntüsü ve (D)'deki ROI'si izlenmektedir.

**Olgu 3:** 56 yaşında erkek Onkositom olgusu (Şekil 18).



**Şekil 18.** Onkositom olgusunun sol böbrek orta kesim posteriyorundaki 30x32mm boyutlu lezyon izlenmektedir.

(A) kontrast sonrası 30.sn. T1 ağırlıklı görüntü ve (B)'deki manüel olarak çizilen ROI'si ile (C) kontrast sonrası 70.sn. T1 ağırlıklı görüntü ve (D)'deki çizilen ROI'si izlenmektedir.

## 6. TARTIŞMA

Bu çalışmada radyolojik görüntüleme yapı çözümü uygulama tekstür analizi kullanarak yöntemin RHK ve onkositom ayırıcı tanısındaki yeri, RHK alt tiplerini sınıflamadaki katkısı ile nükleer derece ve tekstür verileri arasındaki ilişki gösterilmiştir. Çalışma literatürde böbrek kitleleri ile ilgili olarak MR datası üzerinden yapılan bizim bildiğimiz ilk tekstür analiz çalışmasıdır. Daha önce böbrek kitlelerine yönelik tekstür analizi çalışmaları BT verileri üzerinden yapılmıştır.

Raman ve ark. TexRAD yazılımıyla dinamik BT verilerini kullanarak yaptıkları çalışmada berrak hücreli RHK, papiller RHK, onkositom ve kist ayırıcı tanısında tekstür özelliklerinin faydalı olduğunu göstermiştir. Random forest modeli kullanarak yaptıkları sınıflamada onkositomların %89'unu, berrak hücreli RHK'lerin %91'ini, kistlerin %100'ünü ve papiller RHK'lerin %100'ünü doğru sınıflayabilmişlerdir. Bu çalışmada gruplar arasında kromofob hücreli RHK'ye ait olgu bulunmamaktadır (53).

Schieda ve ark. MaZda yazılımı ile BT verilerinde yaptıkları sarkomatoid RHK ve berrak hücreli RHK gruplarını değerlendirdikleri çalışmada tekstür özelliklerinin boyut ve vasküleritenin yanında bu iki hasta grubunu ayırt etmede yararlı olduğunu göstermişlerdir. RLM parametrelerinden tekrar-uzunluğu düzensizliği ve grilik-seviyesi düzensizliği parametrelerinin sarkomatoid RHK'de daha yüksek değerlerde olduğu ve aralarındaki farkın anlamlı olduğu ifade edilmiştir (54).

Hodgdon ve ark. MaZda yazılımıyla istatistiksel tekstür analizi parametresini kullandıkları kontrastsız BT görüntüleri ile yaptıkları çalışmada yağdan fakir AML ve RHK ayırıcı tanısında tekstür özelliklerinin yararlı olduğunu göstermişlerdir. Çalışmalarında RHK alt tiplerini ayırmada tekstür parametrelerinin yarar sağlamadığını belirtmişlerdir (55).

Schieda ve ark. MaZda yazılımını kullanarak yaptıkları bir başka çalışmalarında kromofob RHK'ler için düşük ve yüksek dereceli olguların ayırımında tekstür özelliklerinin yararlı olduğunu göstermiştir (56).



Koçak ve ark. kontrastsız ve kontrastlı BT görüntülerini kullanarak yaptıkları makine öğrenme temelli çalışmada tekstür analiz verilerinin RHK ve RHK-dışı lezyonları ayırt etmede faydalı olduğunu göstermiştir. Lojistik regresyon modeli ve ROC eğrisi kullandıkları bu çalışmada kombine tekstür özelliklerinin yüksek dereceli tümörleri saptayabildiğini göstermişlerdir (Maksimum eğri altındaki alan (EAA)  $0.84 \pm 0.06$  ( $p < 0.0001$ ) olarak ifade edilmiştir) (57).

Malign kitle şüphesiyle böbrekten opere olan önemli sayıda olgunun sonrasında histopatolojik tanısının benign olduğu görülmektedir. Kutikov ve ark. soliter böbrek kitlesi nedeniyle parsiyel nefrektomi yapılan 143 olgunun değerlendirdiği çalışmada olguların %16.1'inin histopatolojik tanısının benign olduğunu göstermiştir (1). Ayrıca literatürde kromofob RHK'lerin ve onkositomların morfolojik, histokimyasal, immünohistolojik olarak kesişen bulgularının olduğu, ve bu ortak özelliklerin ayırıcı tanıda güçlük yarattığı bilinmektedir (7,58).

Çalışmada tekstür analizinin uygulandığı sekanslara ait veriler değerlendirildiğinde;

Kontrast sonrası 30.sn. T1 ağırlıklı görüntülerde olguların %95'i doğru sınıflanmıştır (berrak hücreli RHK için duyarlılık %91,6, özgüllük %100; papiller RHK için duyarlılık %100, özgüllük %100; kromofob RHK için duyarlılık %100, özgüllük %75; onkositom için duyarlılık %100, özgüllük %100).

Kontrast sonrası 70.sn. T1 ağırlıklı görüntülerde olguların %100'ü doğru sınıflanmıştır (berrak hücreli RHK için duyarlılık %100, özgüllük %100; papiller RHK için duyarlılık 100%, özgüllük %100; kromofob RHK için duyarlılık %100, özgüllük %100; onkositom için duyarlılık %100, özgüllük %100).

T2 Ağırlıklı görüntüler 8 bit/piksele indirgenip özellik seçimi Fisher katsayısı kullanılarak yapıldığında olguların %100'ü doğru sınıflanmıştır (berrak hücreli RHK için duyarlılık %100, özgüllük %100; papiller RHK için duyarlılık %100, özgüllük %100; kromofob RHK için duyarlılık %100, özgüllük %100; onkositom için duyarlılık %100, özgüllük %100). T2 Ağırlıklı görüntüler POE+ACC yöntemiyle seçilip hem 6bit/piksele hem 8bit/piksele indirgenerek değerlendirildiğinde olguların

%96,2'si doğru sınıflanmıştır (berrak hücreli RHK için duyarlılık %94,1, özgüllük %100; papiller RHK için duyarlılık %100, özgüllük %100; kromofob RHK için duyarlılık %100, özgüllük %100; onkositom için duyarlılık %100, özgüllük %75).

SPAIR T2 görüntülerde olguların %89,3'ü doğru sınıflanmıştır (berrak hücreli RHK için duyarlılık %94,7, özgüllük %90, papiller RHK için duyarlılık %66,6, özgüllük %100; kromofob RHK için duyarlılık %100, özgüllük %75; onkositom için duyarlılık %66,6, özgüllük %100).

Dış faz görüntülerde olguların %93,3'ü doğru sınıflanmıştır (berrak hücreli RHK için duyarlılık %95, özgüllük %95; papiller RHK için duyarlılık %100, özgüllük %100; kromofob RHK için duyarlılık %66,6, özgüllük %100; onkositom için duyarlılık %100, özgüllük %75).

ADC görüntülerde olguların %75,9'u doğru sınıflanmıştır (berrak hücreli RHK için duyarlılık %78,9, özgüllük %93,7; papiller RHK için duyarlılık %20, özgüllük %100; kromofob RHK için duyarlılık %100, özgüllük %100; onkositom için duyarlılık %50, özgüllük %25).

Çalışmada, yapı çözümüleme uygulaması olan tekstür analizi ile elde olunan MR tekstür parametreleri kullanılarak RHK ve onkositom ayrımının %100'e ulaşan doğrulukla yapılabildiği görülmüştür. Beraberinde kromofob RHK olguları incelenen tüm sekanslarda diğer gruplara benzemez yapıda izlenmiştir. Bu bulgu onkositom, kromofob RHK ayrımında önem taşımaktadır.

Nükleer derecenin belirlenmesi amacıyla tekstür analiz verileri daha önce RHK nükleuslarının mikroskobik görüntüleri kullanılarak çalışılmıştır. Kim ve ark. yaptıkları bu çalışmada 3B tekstür analizi ile olguların %78'i doğru sınıflanmıştır (59).

Başka bir çalışmada Schieda ve ark. BT kesitleri üzerinden tekstür verileri ile yüksek ve düşük evreli Kromofob RHK'ler ayırabilmiştir (56).

Bu çalışmada da tekstür özellikleri berrak hücreli RHK olgularında düşük evre- yüksek evre ayrımında yarar sağlamıştır. Çalışmada ADC ve kontrast sonrası

70.sn. tekstür verilerine göre olguların tamamı doğru sınıflanabilmiştir. T2 ağırlıklı görüntülerdeki tekstür özellikleri ise ile olguların %93,8'i doğru sınıflanabilmiştir.

İndirgenen grilik değerlerinin tekstür analiz sonuçlarını etkilediği bazı çalışmalarda gösterilmiştir. Mahmoud-Ghoneim ve ark. yaptıkları çalışmada grilik değerinin analiz sonuçlarını etkilediğini, beyin beyaz cevheri ile yapılan çalışmada en iyi sonucun 128 grilik değeriyle yapıldığını göstermiştir (60). Bu tez çalışmasında T2 verileri (6bit/piksel) 64 grilik değerine indirgenerek ve (8bit/piksel)256 grilik değerine indirgenerek değerlendirilmiştir. İki analiz de olguların %96,2 sini doğru olarak sınıflamış, indirgenen grilik değeri söz konusu olduğunda iki analiz arasında sınıflama başarısı açısından farklılık olmadığı değerlendirilmiştir.

Bu çalışmada T2 verileri üzerinden özellik seçimi işlemleri hem Fisher katsayısı hem de POE+ACC yöntemi kullanılarak yapılmıştır. Fisher katsayısı kullanılarak yapılan incelemede sınıflama başarısı daha yüksek bulunmuştur. T2 verilerine ait Fisher katsayısı kullanılarak seçilen tekstür özellikleri olguların tamamını, POE+ACC yöntemi kullanılarak seçilen tekstür özellikleri olguların %96,2'sini doğru sınıflamıştır.

Literatürdeki ilk çalışmalar tekstür analizinin tek cihazda tek protokolde çekilmiş hastalarda uygulanmasını önermektedir. Ancak yapılan başka çalışmalar uygun normalizasyon yöntemleri ile birlikte kullanıldığında farklı cihazlardaki farklı protokollerin ve hatta farklı merkezdeki görüntülerin de birlikte kullanılabilceğini göstermektedir (15). Buradan yola çıkarak bu çalışmada farklı cihaz ve parametre verileri birlikte kullanılabilmiştir.

Google'ın akademik platformunda "MaZda" ve "texture" anahtar kelimeleri birlikte tarandığında 2010-2019 yılları arasında yapılmış 1800'ün üzerinde MaZda uygulaması kullanılarak yapılmış çalışma görülmektedir. Fruehwald-Pallamar ve ark. MaZda yazılımını kullandıkları iki ayrı merkezde elde edilen 100 MR incelemesine ait verileri değerlendirdikleri çalışmada tekstür özelliklerinin malign ve benign baş-boyun tümörlerini ayırt etmede faydalı olduğunu göstermişlerdir. Normalizasyon yöntemi kullanılmadan yapılan bu çalışmada tek cihaz verilerinin ayırt edici gücünün daha yüksek olduğu belirtilmiştir (15).

Muehlematter ve ark. MaZda yazılımını kullanarak BT tetkiklerinde yapıları çalışmada tekstür özelliklerinin vertebralarda yetmezlik fraktürü riskini göstermede faydalı olduğunu ifade etmişlerdir. 58 Hastada 120 vertebra değerlendirilmiş. Support vector machine sınıflayıcısı kullanarak seçilen 29 tekstür özelliği birlikte değerlendirilmiş ve eğri altındaki alan 0,97 olarak hesaplanmış (61).

Hui ve ark. MaZda yazılımını kullanarak 50 olguda yaptıkları çalışmada MR verilerindeki tekstür özelliklerinin hepatosellüler karsinom nedeniyle opere olmuş olgularda rekürrens riskini göstermede yarar sağlayabileceğini göstermiştir. Yaptıkları çalışmada ayırıcı özelliğin en yüksek olduğu tekstür parametrelerini denge fazındaki görüntülerde  $S(4,0)SumVarn$ ,  $S(0,3)SumOfSq$ , ve  $S(1,1)DifVarn$  olarak bulmuşlar ve doğruluk oranlarını sırasıyla %84, %82 ve %78 olarak hesaplamışlar (62).

Holli-Helenius ve ark. MaZda yazılımını MR görüntülerinde kullanarak Luminal A ve Luminal B moleküler alt tiplerdeki duktal meme kanseri tanı olgularda yaptıkları çalışmada tekstür verilerinin ve hacim verilerinin meme kanserinin biyolojik agresifliğini göstermede yarar sağlayabileceğini belirtmişlerdir. Luminal A ve luminal B gruplarının ayırıcılığı en yüksek iki özellik sum-entropy ve sum-variance olarak belirtilmiş Bu iki parametre birlikte kullanıldığında ROC analizi ile EAA 0,878 olarak hesaplanmış (63).

MaZda dışında başka tekstür analiz yazılımları kullanılarak yapılan bir çalışmada Zacharaki ve ark. MR görüntülerinin tekstür özelliklerinin menenjiomları, WHO grade II gliomları, WHO grade III gliomları, glioblastomları ayırmada yararlı olduğunu göstermişlerdir (64).

Skogen ve ark. TexRAD kullanarak yaptıkları çalışmada tek soliter beyin metastazı olan olgular ve glioblastom olguları arasında MR kesitleri üzerinden yaptıkları çalışmada tekstür özelliklerinin lezyonların solid kesimlerinde benzer olduğunu ancak peritümöral alandaki tekstür özelliklerinin ayırıcı tanıda faydalı olduğunu göstermişlerdir (65).

Literatürde farklı tekstür analiz yazılımlarının sonuçlarının birbiri içinde tutarlı ancak birbirlerinden farklı olduğu gösterilmiştir. Béresová ve ark.'ları

yaptıkları çalışmada oluşturdukları sentetik imajlar ile farklı tekstür analiz yazılımlarını (CGITA, InterView Fusion, Matlab, MaZda) histogram ve COM parametrelerini kullanarak birbirleriyle kıyaslamışlar. Yapılan analizler sonucunda çalışılan 22 parametreden 5'inin programlar arasında %20'den fazla değişiklik gösterdiğini ve kabul edilebilir sonuçlar için en az 64 normalizasyon seviyesinin gerektiğini belirtmişler (66). Bu nedenle aynı yazılım kullanılarak elde edilen sonuçların değerlendirilmesi önerilmektedir.

Bu çalışmanın sınırlılıkları mevcuttur:

En önemli sınırlılık olgu gruplarının küçük oluşu, çalışmanın genişletilmiş bir olgu kontrol çalışması özellikleri taşımasıdır. Vaka-kontrol çalışmalarının tanısal doğruluğu abarttığı bilinmektedir (55,67). Sonraki çalışmalar için daha geniş olgu gruplarında çalışmaya ihtiyaç vardır.

Bir diğer sınırlama böbrek kitlelerinin ayırıcı tanısında önemli bir yeri olan yağdan fakir anjiomiyolipom olgularının olmayışıdır.

Çalışmadaki olguların görüntüleri 3 ayrı cihazdan (1 3T ve 2 1.5T) elde edilmişti, ancak çekim protokolleri birbirine benzer özellikteydi. Literatürdeki çalışmalar her ne kadar normalizasyon yöntemlerinin etkili olduğunu gösterecek de tek cihazda aynı protokolda elde edilmiş görüntüler ile yapılan çalışmaların güvenilirliğinin daha yüksek olduğu ifade edilmektedir (16).

Çalışma lezyonun en geniş olarak izlendiği tek kesitten 2B tekstür analizi şeklinde yapılmıştır. 3B analize olanak verecek ince kesitlerin elde olunduğu data ile analizin intratümöral varyasyonları daha iyi yansıtabileceği düşünülmektedir (15).

Son olarak çalışılan tekstür parametreleri MaZda programının analiz edebildikleri ile sınırlı bulunmaktaydı. Bununla birlikte literatürde doku tekstür özelliklerini göstermek için daha farklı analiz modelleri de mevcuttur. Bunları birlikte analiz edebilecek bir uygulama, doku tekstür özelliklerini daha yüksek doğrulukla yansıtabilir.

## 7. SONUÇ

Sonuç olarak radyolojik görüntüleme yapı çözümü uygulama uygulaması tekstür analiz verilerinin böbrek kitlelerinden RHK ve onkositomun ayırıcı tanısında, RHK alt tiplerini sınıflamada, Berrak hücreli RHK olgularında nükleer dereceyi ortaya koymada yararlı olabileceği bilgisi edinilmiştir.

Tekstür analiz sonuçları ile en iyi ayırt edici özellikler sırasıyla kontrast sonrası 70.sn. T1 ağırlıklı görüntüler, T2 ağırlıklı görüntüler ve kontrast sonrası 30.sn. T1 ağırlıklı görüntülerde (sırasıyla %100, %100 ve %95 olgu doğru sınıflanmıştır.) elde edilmiştir.

MaZda programı ile özellik seçimi için kullanılan Fisher kat sayısı ile seçilen veriler daha doğru sınıflanmış, Fisher katsayısı ve POE+ACC yöntemlerinin başarıları birbirine yakın bulunmuştur. Görüntülerin bit/piksel değerinin değiştirilmesi (256 grilik ve 64 grilik değeri için) tekstür özelliklerinin ayırt edilmesinde böbrek kitleleri söz konusu olduğunda belirgin farklılığa neden olmamıştır.

Çalışma farklı cihazlarda farklı protokollerle elde edilen benzer sekansların tekstür özellikleri açısından normalizasyon işlemi sonrasında başarıyla uygulanabileceğini göstermiştir.

Böbrek kitlelerinin preoperatif değerlendirilmesinin çoğunlukla BT ile yapılması, çoğu merkezin ön değerlendirmede MR kullanmaması nedeniyle çalışmanın veri seti küçük olup daha geniş hasta popülasyonlarında bulguların değerlendirilmesine ihtiyaç duyulmaktadır

## 8. KAYNAKLAR

1. Kutikov A, Fossett LK, Ramchandani P, Tomaszewski JE, Siegelman ES, Banner MP, et al. Incidence of benign pathologic findings at partial nephrectomy for solitary renal mass presumed to be renal cell carcinoma on preoperative imaging. *Urology*. 2006 Oct 1;68(4):737–40.
2. Larroza A, Bodí V, Moratal D. Texture Analysis in Magnetic Resonance Imaging: Review and Considerations for Future Applications. In: *Assessment of Cellular and Organ Function and Dysfunction using Direct and Derived MRI Methodologies*. InTech; 2016. p. 75–106.
3. Wang M, Feng Z. MR texture analysis in differential diagnosis of glioblastoma and solitary metastatic brain tumor. *Western Pacific Region Index Medicus*. 2017;33(12):1784–7.
4. Ren J, Wu Y, Tao X. MRI texture analysis in differential diagnosis of orbital lymphoma and inflammatory pseudotumor. *Western Pacific Region Index Medicus*. 2017;33(7):980–4.
5. Huang Z, Li M, He D, Wei Y, Yu H, Wang Y, et al. Two-dimensional Texture Analysis Based on CT Images to Differentiate Pancreatic Lymphoma and Pancreatic Adenocarcinoma: A Preliminary Study. Elsevier.
6. Lopes Vendrami C, Parada Villavicencio C, DeJulio TJ, Chatterjee A, Casalino DD, Horowitz JM, et al. Invited Commentary on “Differentiation of Solid Renal Tumors with Multiparametric MR Imaging.” *RadioGraphics*. 2017 Nov 13;37(7):2042–4.
7. Rosenkrantz AB, Hindman N, Fitzgerald EF, Niver BE, Melamed J, Babb JS. MRI Features of Renal Oncocytoma and Chromophobe Renal Cell Carcinoma. *American Journal of Roentgenology*. 2010 Dec 23;195(6):W421–7.
8. Cornelis F, Tricaud E, Lasserre AS, Petitpierre F, Bernhard JC, Le Bras Y, et al. Routinely performed multiparametric magnetic resonance imaging helps to differentiate common subtypes of renal tumours. *European Radiology*. 2014 May 21;24(5):1068–80.

9. Türk Dil Kurumu [Internet]. [cited 2019 May 12]. Available from: [http://www.tdk.gov.tr/index.php?option=com\\_bts&view=bts&kategori1=veritbn&kelimesec=307863](http://www.tdk.gov.tr/index.php?option=com_bts&view=bts&kategori1=veritbn&kelimesec=307863)
10. Mirmehdi M, Xie X, Suri J. Handbook of Texture Analysis. Handbook of Texture Analysis. Imperial College Press And Distributed By World Scientific Publishing Co.; 2012.
11. William Henry Nailon. Texture analysis methods for medical image characterisation. Biomedical Imaging. 2010;
12. Haralick RM. Statistical and structural approaches to texture. Proceedings of the IEEE. 1979;67(5):786–804.
13. Hawkins JK. Textural properties for pattern recognition. In: Picture Processing and Psychopictorics. Elsevier Science; 1970. p. 535.
14. Lerski RA, Straughan K, Schad LR, Boyce D, Blüml S, Zuna I. VIII. MR image texture analysis-An approach to tissue characterization. Magnetic Resonance Imaging. 1993 Jan 1;11(6):873–87.
15. Fruehwald-Pallamar J, Hesselink JR, Mafee MF, Holzer-Fruehwald L, Czerny C, Mayerhoefer ME. Texture-Based Analysis of 100 MR Examinations of Head and Neck Tumors - Is It Possible to Discriminate between Benign and Malignant Masses in a Multicenter Trial? RoFo Fortschritte auf dem Gebiet der Rontgenstrahlen und der Bildgebenden Verfahren. 2016 Feb 1;188(2):195–202.
16. Mayerhoefer ME, Szomolanyi P, Jirak D, Materka A, Trattnig S. Effects of MRI acquisition parameter variations and protocol heterogeneity on the results of texture analysis and pattern discrimination: An application-oriented study. Medical Physics. 2009 Mar 18;36(4):1236–43.
17. McNitt-Gray M. Tradeoffs in CT Image Quality and Dose. Med Phys. 2006;33.
18. Redpath T. Signal-to-noise ratio in MRI. The British journal of radiology. 1998;71:704–7.



19. Mackin D, Ger R, Dodge C, Fave X, Chi P-C, Zhang L, et al. Effect of tube current on computed tomography radiomic features. *Scientific Reports*. 2018 Dec 5;8(1):2354.
20. Yasaka K, Akai H, Mackin D, Court L, Moros E, Ohtomo K, et al. Precision of quantitative computed tomography texture analysis using image filtering. *Medicine (United States)*. 2017;96(21).
21. Babak A, Thomas W, Hans-Jürgen R, Frank W, Hoen-oh S. Effect of an advanced model-based iterative reconstruction algorithm on texture and visual impression of images provided by a dual source CT scanner. 2018 Sep 14;
22. Herlidou-Même S, Constans J. M, Carsin B, Olivie D, Eliat P. A, Nadal-Desbarats L, et al. MRI texture analysis on texture test objects, normal brain and intracranial tumors. *Magnetic Resonance Imaging*. 2003 Nov 1;21(9):989–93.
23. Mayerhoefer ME, Breitenseher MJ, Kramer J, Aigner N, Hofmann S, Materka A. Texture analysis for tissue discrimination on T1-weighted MR images of the knee joint in a multicenter study: Transferability of texture features and comparison of feature selection methods and classifiers. *Journal of Magnetic Resonance Imaging*. 2005 Nov 1;22(5):674–80.
24. Köhli P, Järnstedt J, Sikiö M, Viik J, Dastidar P, Peltomäki T, et al. A texture analysis method for MR images of airway dilator muscles: A feasibility study. *Dentomaxillofacial Radiology*. 2014 Jul;43(5):20130403.
25. Li H, Giger ML, Huo Z, Olopade OI, Lan L, Weber BL, et al. Computerized analysis of mammographic parenchymal patterns for assessing breast cancer risk: Effect of ROI size and location. *Medical Physics*. 2004 Feb 17;31(3):549–55.
26. Sikiö M, Holli-Helenius KK, Ryymin P, Dastidar P, Eskola H, Harrison L. The effect of region of interest size on textural parameters. In: 9th International Symposium on Image and Signal Processing and Analysis, ISPA 2015. IEEE; 2015. p. 149–53.

27. Mayerhoefer ME, Szomolanyi P, Jirak D, Berg A, Materka A, Dirisamer A, et al. Effects of magnetic resonance image interpolation on the results of texture-based pattern classification a phantom study. *Investigative Radiology*. 2009 Jul;44(7):405–11.
28. Materka A, Strzelecki M, Lerski R, Schad L. Feature Evaluation of Texture Test Objects for Magnetic Resonance Imaging. In 2010. p. 197–206.
29. Loizou CP, Pantziaris M, Seimenis I, Pattichis CS. Brain MR image normalization in texture analysis of multiple sclerosis. In: Final Program and Abstract Book - 9th International Conference on Information Technology and Applications in Biomedicine, ITAB 2009. IEEE; 2009. p. 1–5.
30. Boyes RG, Gunter JL, Frost C, Janke AL, Yeatman T, Hill DLG, et al. Intensity non-uniformity correction using N3 on 3-T scanners with multichannel phased array coils. *NeuroImage*. 2008 Feb 15;39(4):1752–62.
31. Held M, Cremers F, Sneed PK, Braunstein S, Fogh SE, Nakamura J, et al. Assessment of image quality and dose calculation accuracy on kV CBCT, MV CBCT, and MV CT images for urgent palliative radiotherapy treatments. *Journal of Applied Clinical Medical Physics*. 2016 Mar 1;17(2):279–90.
32. Lang A, Carass A, Jedynek BM, Solomon SD, Calabresi PA, Prince JL. Intensity inhomogeneity correction of macular OCT using N3 and retinal flatspace. In: Proceedings - International Symposium on Biomedical Imaging. IEEE; 2016. p. 197–200.
33. McAuliffe MJ, Lalonde FM, McGarry D, Gandler W, Csaky K, Trus BL. Medical Image Processing, Analysis and Visualization in clinical research. In 2002. p. 381–6.
34. Castellano G, Bonilha L, Li LM, Cendes F. Texture analysis of medical images. *Clinical Radiology*. 2004 Dec 1;59(12):1061–9.
35. Materka A. Texture analysis methodologies for magnetic resonance imaging. Vol. 6, Dialogues in Clinical Neuroscience. Les Laboratoires Servier; 2004. p. 243–50.

36. Harrison L, Holli KK, Lääperi AL, Soimakallio S, Dastidar P, Eskola H. Clinical applicability of MRI texture analysis. *Computational Vision and Medical Image Processing: VipIMAGE 2009*. 2009;409.
37. Haralick RM, Dinstein I, Shanmugam K. Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*. 1973 Nov;SMC-3(6):610–21.
38. Tomita F, Tsuji S. Statistical Texture Analysis. In: *Computer Analysis of Visual Textures*. Boston, MA: Springer US; 1990. p. 13–36.
39. Tang X, Xiaoou Tang. Texture information in run-length matrices. *IEEE transactions on image processing*. 1998;7(11):1602–9.
40. Harrison L, Dastidar P, Eskola H, Järvenpää R, Pertovaara H, Luukkaala T, et al. Texture analysis on MRI images of non-Hodgkin lymphoma. *Computers in Biology and Medicine*. 2008 Apr 1;38(4):519–24.
41. TexRAD (Texture + Radiology) [Internet]. [cited 2019 May 11]. Available from: <https://fbkmed.com/textrad-landing-2/>
42. LIFEx [Internet]. [cited 2019 May 11]. Available from: <https://www.lifexsoft.org/>
43. Zhang L, Fried D V, Fave XJ, Hunter LA, Yang J, Court LE. IBEX: an open infrastructure software platform to facilitate collaborative work in radiomics. *Medical physics*. 2015 Mar;42(3):1341–53.
44. Wu X, Shu X. Epidemiology of renal cell carcinoma. In: *Renal Cell Carcinoma: Molecular Features and Treatment Updates*. Elsevier; 2017. p. 1–18.
45. Kay FU, Pedrosa I. Imaging of Solid Renal Masses. Vol. 45, *Urologic Clinics of North America*. NIH Public Access; 2018. p. 311–30.
46. Flum AS, Hamoui N, Said MA, Yang XJ, Casalino DD, McGuire BB, et al. Update on the Diagnosis and Management of Renal Angiomyolipoma. Vol. 195, *Journal of Urology*. 2016. p. 834–46.

47. Sasaguri K, Takahashi N. CT and MR imaging for solid renal mass characterization. Vol. 99, *European Journal of Radiology*. Elsevier; 2018. p. 40–54.
48. Moch H, Cubilla AL, Humphrey PA, Reuter VE, Ulbright TM. The 2016 WHO Classification of Tumours of the Urinary System and Male Genital Organs—Part A: Renal, Penile, and Testicular Tumours. *European Urology*. 2016 Jul 1;70(1):93–105.
49. Cheville JC, Lohse CM, Zincke H, Weaver AL, Blute ML. Comparisons of outcome and prognostic features among histologic subtypes of renal cell carcinoma. *The American journal of surgical pathology*. 2003 May;27(5):612–24.
50. Muglia VF, Prando A. Renal cell carcinoma: histological classification and correlation with imaging findings. *Radiologia Brasileira*. 2015 Jun;48(3):166–74.
51. Kang SK, Huang WC, Pandharipande P V., Chandarana H. Solid Renal Masses: What the Numbers Tell Us. *American Journal of Roentgenology*. 2014 Jun 21;202(6):1196–206.
52. Wang ZJ, Westphalen AC, Zagoria RJ. CT and MRI of small renal masses. *The British Journal of Radiology*. 2018 May 10;20180131.
53. Raman SP, Chen Y, Schroeder JL, Huang P, Fishman EK. CT Texture Analysis of Renal Masses: Pilot Study Using Random Forest Classification for Prediction of Pathology. *Academic Radiology*. 2014 Dec 1;21(12):1587–96.
54. Schieda N, Thornhill RE, Al-Subhi M, McInnes MDFF, Shabana WM, Van Der Pol CB, et al. Diagnosis of sarcomatoid renal cell carcinoma with CT: evaluation by qualitative imaging features and texture analysis. *American Journal of Roentgenology*. 2015 May 23;204(5):1013–23.
55. Hodgdon T, McInnes MDF, Schieda N, Flood TA, Lamb L, Thornhill RE. Can Quantitative CT Texture Analysis be Used to Differentiate Fat-poor Renal Angiomyolipoma from Renal Cell Carcinoma on Unenhanced CT Images? *Radiology*. 2015 Sep 23;276(3):787–96.

56. Schieda N, Lim RS, Krishna S, McInnes MDF, Flood TA, Thornhill RE. Diagnostic accuracy of unenhanced CT analysis to differentiate low-grade from high-grade chromophobe renal cell carcinoma. *American Journal of Roentgenology*. 2018 May;210(5):1079–87.
57. Kocak B, Yardimci AH, Bektas CT, Turkcanoglu MH, Erdim C, Yucetas U, et al. Textural differences between renal cell carcinoma subtypes: Machine learning-based quantitative computed tomography texture analysis with independent external validation. *European Journal of Radiology*. 2018 Oct;107:149–57.
58. Tickoo SK, Amin MB. Discriminant nuclear features of renal oncocytoma and chromophobe renal cell carcinoma: Analysis of their potential utility in the differential diagnosis. *American Journal of Clinical Pathology*. 1998 Dec 1;110(6):782–7.
59. Kim TY, Choi HJ, Hwang HG, Choi HK. Three-dimensional texture analysis of renal cell carcinoma cell nuclei for computerized automatic grading. *Journal of Medical Systems*. 2010 Aug 8;34(4):709–16.
60. Mahmoud-Ghoneim D, Alkaabi MK, de Certaines JD, Goettsche FM. The impact of image dynamic range on texture classification of brain white matter. *BMC Medical Imaging*. 2008 Dec 23;8(1):18.
61. Muehlematter UJ, Mannil M, Becker AS, Vokinger KN, Finkenstaedt T, Osterhoff G, et al. Vertebral body insufficiency fractures: detection of vertebrae at risk on standard CT images using texture analysis and machine learning. *European Radiology*. 2019 May 5;29(5):2207–17.
62. Hui TCH, Chuah TK, Low HM, Tan CH. Predicting early recurrence of hepatocellular carcinoma with texture analysis of preoperative MRI: a radiomics study. *Clinical Radiology*. 2018 Dec;73(12):1056.e11-1056.e16.
63. Holli-Helenius K, Salminen A, Rinta-Kiikka I, Koskivuo I, Brück N, Boström P, et al. MRI texture analysis in differentiating luminal A and luminal B breast cancer molecular subtypes - a feasibility study. *BMC Medical Imaging*. 2017;17(1):69.

64. Zacharaki EI, Wang S, Chawla S, Soo Yoo D, Wolf R, Melhem ER, et al. Classification of brain tumor type and grade using MRI texture and shape in a machine learning scheme. *Magnetic Resonance in Medicine*. 2009 Dec 1;62(6):1609–18.
65. Skogen K, Schulz A, Helseth E, Ganeshan B, Dormagen JB, Server A. Texture analysis on diffusion tensor imaging: discriminating glioblastoma from single brain metastasis. *Acta Radiologica*. 2019 Mar 3;60(3):356–66.
66. Béresová M, Forgács A, Bujdosó B, Székely A, Varga J, Berényi E, et al. Comparing the reliability of biomedical texture analysis tools on different image types. *Acta Polytechnica Hungarica*. 2018;15(7):29–48.
67. Whiting PF, Rutjes AWS, Westwood ME, Mallett S. A systematic review classifies sources of bias and variation in diagnostic test accuracy studies. Vol. 66, *Journal of Clinical Epidemiology*. 2013. p. 1093–104.